



**T.C.**  
**İSKENDERUN TEKNİK ÜNİVERSİTESİ**  
**MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ**

**HATAY AMİK OVASI KUMLU BÖLGESİNDEKİ YERALTI SUYU  
SEVİYESİNİN YAPAY SINIR AĞLARI YÖNTEMİ İLE TAHMİNİ**

**EYÜP İSPİR**

**İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**YÜKSEK LİSANS TEZİ**

**HATAY**

**AĞUSTOS-2017**

**T.C.**  
**İSKENDERUN TEKNİK ÜNİVERSİTESİ**  
**MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ**

**HATAY AMİK OVASI KUMLU BÖLGESİNDEKİ YERALTI SUYU  
SEVİYESİNİN YAPAY SİNİR AĞLARI YÖNTEMİ İLE TAHMİNİ**

**EYÜP İSPİR**

**İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**YÜKSEK LİSANS TEZİ**

**HATAY**  
**AĞUSTOS-2017**

T.C.  
İSKENDERUN TEKNİK ÜNİVERSİTESİ  
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

**HATAY AMİK OVASI KUMLU BÖLGESİNDEKİ YERALTI SUYU  
SEVİYESİNİN YAPAY SİNİR AĞLARI YÖNTEMİ İLE TAHMİNİ**

**EYÜP İSPİR  
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI  
YÜKSEK LİSANS TEZİ**

Doç. Dr. Mustafa DEMİRCİ (1. Danışman) ve Doç. Dr. Fatih ÜNEŞ' in (2. Danışman) danışmanlıklarında hazırlanan bu tez 17/08/2017 tarihinde aşağıdaki jüri üyeleri tarafından OYBİRLİĞİ ile kabul edilmiştir.

Doç. Dr. Mustafa DEMİRCİ  
Başkan

Doç. Dr. Fatih ÜNEŞ  
Üye

Doç. Dr. Ahmet İRVEM  
Üye

Yrd. Doç. Dr. Cuma KARAKUŞ  
Üye

Doç. Dr. Muharrem KARAASLAN  
Üye

**Kod No: 64**

**Doç. Dr. Mustafa DEMİRCİ  
Enstitü Müdürü**

**Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.**

17.08.2017

## **TEZ BİLDİRİMİ**

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını ve tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülendiğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu beyan ederim.

Eyüp İSPİR

## ÖZET

### HATAY AMİK OVASI KUMLU BÖLGESİNDEKİ YERALTI SUYU SEVİYESİNİN YAPAY SİNİR AĞLARI YÖNTEMİ İLE TAHMİNİ

Stratejik bir kaynak niteliğinde olan yeraltı suyundan ülkemizde içme-kullanma, tarımsal sulama ve sanayi maksatlı önemli miktarda çekim yapılmaktadır. Nüfus artışı ile birlikte toplam su tüketimi sürekli artmaktadır. Su ihtiyacının karşılanabilmesi amacıyla yeraltı sularından yapılan aşırı çekimler neticesinde yeraltı su seviyesinde önemli düşmeler meydana gelmektedir. Etkin ve sürdürülebilir yeraltı suyu yönetiminin planlanabilmesi için yeraltı su seviyesinin tahmin edilmesi önem arz etmektedir.

Bu çalışmada Hatay Amik Ovası Kumlu bölgesinde bulunan Devlet Su İşleri Genel Müdürlüğü (DSİ) rasat kuyusuna ait 2000 ile 2015 yılları arasındaki yeraltı su seviyesi aylık ölçüm değerleri ile bölgenin aylık toplam yağış ve ortalama sıcaklık değerleri kullanılarak yeraltı suyu seviyesi tahmini yapılmıştır. Bu verilerle Çoklu Lineer Regrasyon (MLR), Otoregresif Model (AR) ve Yapay Sinir Ağları (YSA) modelleri oluşturularak yeraltı su seviyesi tahmininin performans değerlendirilmesi yapılmıştır. Bölgenin yeraltı su seviyesi tahmininde YSA modelinin MLR ve AR modelinden daha iyi sonuç verdiği görülmüştür.

**Anahtar Kelimeler:** Yeraltı suyu seviyesi, tahmin, Amik ovası, yapay sinir ağları.

## ABSTRACT

### ESTIMATION OF GROUNDWATER LEVEL OF KUMLU REGION ON AMIK PLAIN USING ARTIFICIAL NEURAL NETWORKS

Groundwater, which is a strategic resource in Turkey, is used for drinking, agricultural irrigation and industrial purposes. Population increase and total water consumption are constantly increasing. In order to meet the need for water, over-shoots from underground water have caused significant falls in groundwater level. Estimation of water level is important for planning an efficient and sustainable groundwater management.

In this study, groundwater level prediction was carried out by using the monthly total rainfall, mean temperature and monthly groundwater level values between 2000-2015. Monthly groundwater level values were obtained from observation well of The General Directorate of State Hydraulic Works, located Kumlu Region in Hatay Amik Plain. The performance evaluation was done by creating Multi Linear Regression (MLR), Autoregressive (AR) and Artificial Neural Networks (ANN) models. The ANN model gave better results than the MLR and the AR models.

**Key Words:** Groundwater level, prediction, Amik plain, artificial neural networks

## TEŐEKKÜR

Yüksek Lisans çalışmasının ders ve tez aşamasında katkı ve desteklerinden dolayı Doç. Dr. Mustafa DEMİRCİ, Doç. Dr. Fatih ÜNEŐ ve Doç. Dr. Selahattin KOCAMAN'a şükranlarımı sunarım.

Tez çalışmasına sunduđu veriler ile katkı sağlayan Devlet Su İşleri Genel Müdürlüğüne ve Meteoroloji Genel Müdürlüğüne teşekkürlerimi sunarım.

Çalışmalarım sırasında desteđini esirgemeyen eşime hassaten teşekkür ederim.



## İÇİNDEKİLER

ÖZET.....	I
ABSTRACT.....	II
TEŞEKKÜR.....	III
İÇİNDEKİLER .....	IV
ŞEKİLLER DİZİNİ.....	V
ÇİZELGELER DİZİNİ .....	VI
SİMGELER ve KISALTMALAR DİZİNİ .....	VII
1. GİRİŞ .....	1
1.1. Yeraltı Suyunun Bölgeleri.....	3
1.2. Ülkemizde Yeraltı Suyu Potansiyeli .....	4
2. ÖNCEKİ ÇALIŞMALAR.....	6
3. MATERYAL ve YÖNTEM.....	10
3.1. Klasik Yöntemler .....	10
3.1.1. Çoklu Lineer Regresyon Yöntemi (MLR) .....	10
3.1.2. Otoregresif Model (AR(p)) .....	12
3.2. Yapay Sinir Ağları (YSA) Modeli .....	13
3.2.1. Yapay Sinir Ağlarının Biyolojik Kökeni .....	13
3.2.2. Yapay Sinir Hücresi .....	14
3.2.3. Aktivasyon Fonksiyonu Çeşitleri.....	15
3.2.4. Yapay Sinir Ağlarının Sınıflandırılması .....	17
3.2.5. YSA'nın Çalışma Ağının Yapısı.....	19
4. ARAŞTIRMA BULGULARI ve TARTIŞMA .....	26
4.1. Uygulama Alanı ve Tanıtılması .....	26
4.2. Verilerin Değerlendirilmesi.....	27
4.2.1. Model Sonuçları ve Değerlendirilmesi .....	30
4.2.2. Genel Değerlendirme .....	40
5. SONUÇ ve ÖNERİLER.....	41
KAYNAKLAR .....	43
ÖZGEÇMİŞ .....	47
EKLER .....	48
EK 1. Hatay Kumlu Bölgesinde Kullanılan Tüm Verilerin Değerleri.....	48



## ŞEKİLLER DİZİNİ

Şekil 1.1. Hidrolojik döngü .....	1
Şekil 1.2. Dünyadaki suyun dağılımı .....	2
Şekil 1.3. Yeraltı suyunun bölgeleri .....	3
Şekil 1.4. DSİ tarafından tahsisi yapılan yeraltı suyu dağılımı.....	4
Şekil 3.1. Biyolojik sinir hücresinin yapısı.....	14
Şekil 3.2. Yapay sinir ağı modeli.....	15
Şekil 3.3. Doğrusal aktivasyon fonksiyonu.....	16
Şekil 3.4. Adım aktivasyon fonksiyonu .....	16
Şekil 3.5. Sigmoid aktivasyon fonksiyonu.....	17
Şekil 3.6. Tek tabakalı ileri beslemeli ağ.....	19
Şekil 3.7. Tam bağlı ileri beslemeli bir gizli ve çıktı tabakalı hesap ağı.....	20
Şekil 3.8. Çok tabakalı algılayıcı (perceptron).....	23
Şekil 4.1. Amik ovası haritası .....	26
Şekil 4.2. Hatay ili jeoloji haritası .....	27
Şekil 4.3. Aylık toplam yağış yüksekliği değişimi.....	28
Şekil 4.4. Aylık ortalama sıcaklık değişimi.....	28
Şekil 4.5. Aylık yeraltı su seviyesi değişimi.....	29
Şekil 4.6. Yeraltı su seviyesi eğitim verileri için Ölçüm ve MLR dağılım grafiği.....	31
Şekil 4.7. Yeraltı su seviyesi eğitim verileri için Ölçüm ve MLR saçılım grafiği.....	31
Şekil 4.8. Yeraltı su seviyesi test verileri için Ölçüm ve MLR dağılım grafiği.....	32
Şekil 4.9. Yeraltı su seviyesi test verileri için Ölçüm ve MLR saçılım grafiği.....	33
Şekil 4.10. Yeraltı su seviyesi test verileri için Ölçüm ve AR(1) dağılım grafiği.....	34
Şekil 4.11. Yeraltı su seviyesi test verileri için Ölçüm ve AR(1) saçılım grafiği.....	34
Şekil 4.12. Yeraltı su seviyesi test verileri için Ölçüm ve AR(3) dağılım grafiği.....	35
Şekil 4.13. Yeraltı su seviyesi test verileri için Ölçüm ve AR(3) saçılım grafiği.....	35
Şekil 4.14. Yeraltı su seviyesi test verileri için Ölçüm ve AR(5) dağılım grafiği.....	36
Şekil 4.15. Yeraltı su seviyesi test verileri için Ölçüm ve AR(5) saçılım grafiği.....	37
Şekil 4.16. Yeraltı su seviyesi eğitim verileri için Ölçüm ve YSA dağılım grafiği.....	38
Şekil 4.17. Yeraltı su seviyesi eğitim verileri için Ölçüm ve YSA saçılım grafiği.....	38
Şekil 4.18. Yeraltı su seviyesi test verileri için Ölçüm ve YSA dağılım grafiği.....	39
Şekil 4.19. Yeraltı su seviyesi test verileri için Ölçüm ve YSA saçılım grafiği.....	39

## ÇİZELGELER DİZİNİ

Çizelge 4.1. Tüm istatıksel parametre deęişimleri.....	29
Çizelge 4.2. Eğitim ve test istatıksel parametre deęişimleri.....	30
Çizelge 4.3. Kumlu bölgesine ait test verileri için elde edilen parametrelerinin karşılaştırılması.....	40



## SİMGELER ve KISALTMALAR DİZİNİ

### SİMGELER


$W_{kj}$	Bağlantı Ağırlık Katsayısı
$b_k$	Bias terimi
$\varphi(.)$	Aktivasyon Fonksiyonu
$Y_K$	Çıktı Değeri
$X_m$	Girdi Değeri
$V_K$	Girdi sinyallerinden dolayı oluşan lineer bileşen çıktısı
$H_j$	Gizli tabakadaki girdi değeri
$f(H_j)$	Çıktı düğüm noktası değeri
$\eta$	Öğrenme Oranı
$\alpha$	Momentum katsayısı oranı

### KISALTMALAR

AR	Otoregresif Model
BM	Bulanık Mantık
MAE	Ortalama Mutlak Hata
MSE	Ortalama Karesel Hata
R	Korelasyon katsayısı
DSİ	Devlet Su İşleri Genel Müdürlüğü
MGM	Meteoroloji Genel Müdürlüğü
MLR	Çoklu Lineer Regresyon
MTA	Maden Tetkik ve Arama Genel Müdürlüğü
UNEP	United Nations Environment Programme (Birleşmiş Milletler Çevre Programı)
YASS	Yeraltı Su Seviyesi
YSA	Yapay Sinir Ağları

## 1. GİRİŞ

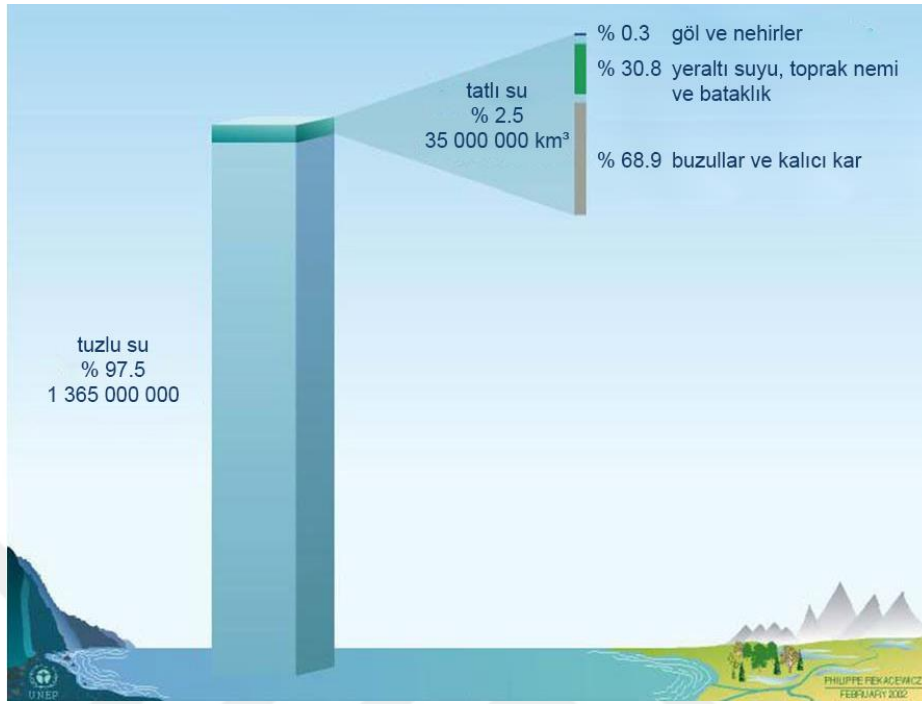
Su, bazı doğal kuvvetler ve hava hareketleriyle atmosfer ile yeryüzündeki karalar ve sular arasında sistemli bir şekilde hareket etmektedir. Buna su döngüsü veya hidrolojik dolaşım denir (Anonim, 2016). Güneş enerjisinin ısıtmasıyla, çeşitli kaynaklardan atmosfere çıkan su buharı; yağmur, kar, dolu gibi yağış biçimleriyle yeniden yeryüzüne döner. Yağışlarla yeryüzüne inen suların bir kısmı akışa geçerek göl ve deniz gibi kaynaklarda birikir, bir kısmı buharlaşır, bir kısmı bitkiler tarafından tutulur ve bir kısmı da yeraltına sızar (Şekil 1.1).



Şekil 1.1. Hidrolojik döngü (USDA, 2016)

Dünyadaki toplam su miktarı 1,4 milyar km<sup>3</sup>'tür. Bu suların %97,5'i okyanuslarda ve denizlerde tuzlu su olarak, %2,5'i ise tatlı su olarak bulunmaktadır. Tatlı suların; %0,3'ü göl ve nehirlerde, %30,8'i yeraltı suyu, toprak nemi ve bataklıklarda, %68,9'u

buzullarda ve kalıcı kar şeklinde bulunmaktadır (UNEP, 2016). Dünyadaki su dağılımı Şekil 1.2.'de gösterilmektedir.




Şekil 1.2. Dünyadaki suyun dağılımı (UNEP, 2016)

Dünyadaki toplam suyun yaklaşık 500000 km<sup>3</sup>'ü her yıl denizlerde ve toprak yüzeyinde meydana gelen buharlaşmalarla atmosfere geri dönmekte ve hidrolojik çevrim içerisinde yağış olarak tekrar yeryüzüne düşmektedir. Yeryüzüne düşen yağış yılda 110000 km<sup>3</sup> olup, bunun 42700 km<sup>3</sup>'ü yüzeysel akışa geçerek nehirlerle denizlere ve kapalı havzalardaki göllere ulaşmaktadır. Bu miktarın da yılda 9000 km<sup>3</sup>'ü teknik ve ekonomik olarak kullanılabilir durumdadır (UNEP, 2016).

Yeryüzünde kullanılan suların % 40'ı yeraltından sağlanmaktadır. Yeraltı su miktarı yeryüzündeki akarsularda bulunan su miktarının 7500 katıdır (Bayazıt, 2003). Yeraltı suyu kurak mevsimlerde akarsuların beslenme kaynağını oluşturur. Yeryüzündeki akarsuların %30'u yeraltından beslenir. Kurak mevsimlerde ancak yeraltı suyuyla beslenen akarsular kurumazlar. Yeraltı suyu doğal bir şekilde filtre edilmiş, bakteri ve organik maddelerden arınmış, depo ve boru masrafı gerektirmeyen, sıcaklık derecesi fazla değişmeyen iyi kalitede su olduğu için önemli bir doğal kaynaktır.

## 1.1. Yeraltı Suyunun Bölgeleri

Yeraltı suyu, gözeneklerin suyla doluluk oranına göre düşey yönde iki bölgeye ayrılır. Doymuş bölgede gözeneklerin tamamı su ile doludur. Bu bölgenin üstünde yer alan doymamış bölgede gözeneklerde hem hava hem de su bulunmaktadır. Yağış sonrası yeryüzünden sızan su önce doymamış bölgeye gelir daha sonra yerçekiminin etkisiyle aşağıya doğru hareket ederek doymuş bölgeye ulaşır. Şekil 1.3.'te yeraltı suyunun bölgeleri görülmektedir.



Şekil 1.3. Yeraltı suyunun bölgeleri (Bayazıt, 2003)

Doymamış bölge yeraltı su yüzeyi ile yer yüzeyi arasında kalan bölgedir. Doymamış bölge zemin nemi, vadoz suyu ve kapiler saçak alt bölgelerinden oluşmaktadır. Kapiler saçak, suyun kapiler (kılcal) gerilmelerle yükselerek tutunduğu saçağa denir. Boşluklarda suyun hava ile birlikte bulunduğu doymamış bölgedeki suya askıda (vadoz) su denir. Zemin nemi bölgesindeki sudan bitkiler köklerinin erişebildiği kadar çekerek faydalanırlar (Bayazıt, 2003).


Doymuş bölgenin üst kısmı yeraltı su yüzeyi ile sınırlanmaktadır. Toprağın suya doygunluğu aslında yeraltı su yüzeyinin üstünde belli bir mesafeye kadar devam etmektedir. Bu mesafe toprağın türüne göre değişmektedir. Kuyular, pınarlar, ve nehirler doymuş bölgedeki sudan beslenmektedir (Bayazıt, 2003).

Boşlukları tamamıyla yeraltı suyuyla dolmuş olan, bu suyu bir noktadan diğerine iletebilen ve böylece boşluklarındaki suyun dışarıya çıkmasına imkan veren formasyonlara akifer denir. Bir jeolojik formasyonun akifer niteliğinde olması için

porozitesinin yeter derecede yüksek olması ve zemindeki boşlukların da oldukça büyük olması gerekmektedir. Akiferler kum, çakıl tabakaları, tortul kütleler, çatlaklı kayalar ve boşluklu kalkerlerden oluşur (Bayazıt, 2003).

## 1.2. Ülkemizde Yeraltı Suyu Potansiyeli

Yeraltı su kaynakları ile ilgili, DSİ Genel Müdürlüğünce 2015 yılı sonuna kadar yapılmış olan hidrojeolojik etütler neticesinde tespit edilmiş olan 18 km<sup>3</sup> yeraltı suyu rezervinin 3,78 km<sup>3</sup>'ü DSİ, kamu kuruluşları ve sulama kooperatiflerine ait devlet eliyle yapılan sulamalarda, 10,81 km<sup>3</sup>'ü ise içme-kullanma ve sanayi suyu ihtiyaçları ile münferit özel sulamalarda olmak üzere 14,6 km<sup>3</sup>'lük bölümünün tahsis işlemi yapılmıştır. (DSİ, 2015). Şekil 1.4.'te DSİ tarafından tahsisi yapılan yeraltı suyu dağılımı görülmektedir.



Şekil 1.4. DSİ tarafından tahsisi yapılan yeraltı suyu dağılımı

Stratejik bir kaynak niteliğinde olan yeraltı suyu ile ülkemizde içme kullanma, tarımsal sulama ve sanayi maksatlı önemli miktarda çekim yapılmaktadır. Göl, sulak alan ve akarsuların akımı, özellikle kurak/yarı kurak bölgelerde ve dönemlerde, yeraltı suyu akışı ile sürdürülür. Yeraltı suyu sistemi dinamiktir ve iklimsel değişimlerden, yeraltı suyu çekiminden ve arazi kullanımından etkilenir.

Nüfus artışı ile birlikte toplam su tüketimi sürekli artmaktadır. Su ihtiyacının karşılanabilmesi amacıyla yeraltı sularından yapılan aşırı çekimler neticesinde yeraltı su seviyesinde önemli düşmeler meydana gelmektedir. Etkin ve sürdürülebilir yeraltı suyu yönetiminin planlanabilmesi için yeraltı su seviyesinin tahmin edilmesi önem arz etmektedir.

Gelecekteki yeraltı suyu seviyesini doğru tahmin edebilmek, gelecekle ilgili doğru karar verebilmek açısından oldukça önemlidir. Geleneksel tahmin seçeneklerinin yanında yapay zeka teknikleri ile de başarılı tahminler yapılabilmektedir.

Bu çalışmada, Hatay Amik ovası Kumlu bölgesine ait önceki yıllarda ölçülen aylık yeraltı su seviyesi verileri ile Çoklu Lineer Regresyon (MLR), Otoregresif Model (AR) ve Yapay Sinir Ağları (YSA) metotları kullanılarak yeraltı su seviyesi tahmin edilmesi amaçlanmıştır.





## 2. ÖNCEKİ ÇALIŞMALAR

Literatüre bakıldığında Yapay Sinir Ağları (YSA) metodu kullanılarak çeşitli çalışmaların yapıldığı görülmektedir. Bugüne kadar YSA birçok farklı disiplinde ve alanlarda kullanılmıştır. YSA, su kaynakları yönetimi ile ilgili birçok araştırmada başarılı olmuştur (Rizzo ve Dougherty, 1994; Çiğizoğlu ve Kişi, 2005).

Yapay Sinir Ağlarının hidrolojide kullanıldığı pek çok çalışma bulunmaktadır. Yüzeysel altına sızma ve zemin nemi tahmini, iklim değişikliği senaryoları, yağışın ve alansal yağışın tahmini, buharlaşma tahmini, sediment tahmini, su kalitesi parametrelerinin belirlenmesi, havza akışının tahmini, akarsu hidrografının elde edilmesi, gibi pek çok çalışmada YSA yöntemi kullanılmıştır (Karaboran, 2013).

Tokar ve Johnson, (1999), YSA teknolojisini günlük akımların; günlük yağış, sıcaklık ve kar erimesi verilerinin fonksiyonu olarak tahmin etmede kullanmışlardır. Campolo ve ark. (1999), YSA'yı yoğun yağış ve düşük akım süreçlerinde nehir akım tahmininde kullanmışlardır. Coppola ve ark. (2003), YSA, kararsız durumdaki bir akiferin, değişik akifer koşulları etkisinde yeraltı su seviyesi dalgalanmasını incelemişlerdir. YSA, aynı zamanda farklı yeraltı suyu problemlerinde kullanılmıştır (Ranjithan vd., 1993; Rogers ve Dowla, 1994). Raman ve Sunilkumar, (1995), YSA'nın sentetik rezervuar akım serileri türetilmesinde kullanılabilirliğini incelemiştir. Boogaard ve diğerleri (1998), AR sinir ağlarını geliştirerek zaman serilerinin lineer olmayan analizinde ve modellenmesine uygulamışlardır. YSA'nın hidroloji uygulamalarındaki kapsamlı değerlendirmeleri Maier ve Dandy, (2000), tarafından yapılmıştır.

Rizzo ve Dougherty, (1994), akifer özelliklerini karakterize etmek için YSA'yı kullanmıştır. Coulibaly ve ark. (2001), aylık yeraltı suyu seviyesi dalgalanmalarının modellenmesi için YSA'ları kullanmıştır. Coppola ve ark. (2005), potansiyometrik yüzey yükselmelerinin doğru tahmin edilmesi için YSA'ları uygulamıştır. Nayak ve ark. (2006), YSA'nın bir kapalı akiferde yeraltı suyu seviyelerini tahmin etme potansiyelini araştırmıştır. Szidarovszky ve diğerleri (2007), sayısal çözümün YSA tahmin edilen değerleri ile sınırlandırılarak sayısal model tahminlerini iyileştirmek için karma bir YSA-sayısal yeraltı suyu akış modeli geliştirmiştir. Coppola ve ark. (2007) karmaşık gerçek dünya yeraltı suyu yönetimi problemleri için çok amaçlı optimizasyon ile YSA modülasyonunun bir kombinasyonunu uygulamıştır. Yoon ve ark., (2007), doymamış gözenekli ortamdaki çözünürlük atılım eğrisini tahmin etmek için YSA'yı kullanmıştır.

Feng ve ark. (2008), insan faaliyetlerinin bölgesel yeraltı suyu seviyelerine etkilerini arařtırmak için YSA'ları uygulamıřtır.

Yücel, (2000), Elazıę Uluova'nın yaęıř ve yeraltı suyu seviye rasatlarından faydalanarak, yeraltı suyu bilançosu hesaplamıřtır. Yaptıkları çalıřmada, limnigraf monte edilmiř kuyuların uzun yıllar aylık yeraltı suyu seviye ölçüm deęerleri ile aylık yaęıř deęerleri kullanılarak ovanın beslenimi bulunmuřtur. Sonra çekim miktarının tayini için abak hazırlanmıř ve yeraltı suyu seviye rasatlarının abaęa yerleřtirilmesi ile yeraltı suyu bilançosu hesaplanmıřtır.

Yurtçu ve ark. (2005), Afyon Akarçay havzasında yer alan beř adet kuyu, dört adet yaęıř, altı adet akıř ve dört adet buharlařma gözlem istasyonu verileri kullanılarak bir istatistiksel modelle yeraltı suyunun davranıřının belirlenmesini arařtırmıřlardır. Verilerde yıl içi periyodik davranıř olup olmadıęını arařtırmak amacıyla periyodogram analizi kullanılmıř ve yeraltı suyunun davranıřında beslenme ve kayıpların etkisini ortaya koyabilmek amacıyla, çoklu regresyon analizi ve korelasyon tekniklerini uygulanmıřlardır.

Akacan, (2005), iki yapay sinir aęları metodu olan radyal tabanlı yapay sinir aęları ve ileri beslemeli geriye yayılım yapay sinir aęları metotlarını, yıllık toplam yaęıř ve yıllık toplam baz akım deęerlerinin eklenik sapmaları ile, yeraltı su seviyesini tahmin etmiřlerdir. Yıllık toplam baz akım ve yıllık toplam ortalama yaęıř deęerlerinin eklenik sapma deęerleri ile tahmin yapılacak yeraltı su seviyesi deęerleri veri olarak kullanılmıřtır. Söz konusu veriler kullanılarak zaman serisinin gelecek yıllardaki deęerlerin tahmini yapılmıřtır.

Tayfur ve Singh, (2006), YSA ve BM yöntemlerini kullanarak olaya dayalı yaęıř-akıř tahminini kinematik dalga yaklařımına göre yapmıřlardır. Bu tahmin için Sigmoid fonksiyonunu ve geriye yayılımlı algoritmayı kullanarak üç tabakalı ileri beslemeli Yapay Sinir Aęları modelini geliřtirmıřlerdir. Dięer yöntem olarak kullandıkları BM modelinde de girdi ve çıktı deęiřkenleri için üçgen üyelik fonksiyonlarını kullanmıřlardır. Küçük bir havza için uygulanan bu modeller akım hidrografi temininde iyi sonuçlar vermiř ve bu modeller deneysel veriler için uygun bulunmuřtur.

Joorabchi ve ark., (2009), YSA metodu ile yeraltı suyu dalgalanmalarını simule etmiřtir. Beř farklı sahil bölgesinden alınan ölçüm verileri kullanılarak, çok katmanlı ileri beslemeli geriye yayılım yapay sinir aęlarını metodu ile eęitilmiřtir. Veri olarak her sahil

bölgesinin, gelgit yüksekliği, sahil eğimi, hidrolik iletkenlik ve sahil taban suyu bilgileri kullanılmıştır. YSA ile geliştirilen model sonucuna göre bir dizi değişkene bağlı olarak tahmin yapmanın çok başarılı olduğunu göstermiştir. Duyarlılık analizi, kıyı akiferlerinde yeraltı suyu seviyesini simule etmek için gelgit yüksekliği varyasyonunun önemli bir parametre olduğunu doğrulamıştır.

Aksoy ve ark. (2011), İzmir Torbalı bölgesinin zamanla değişen yeraltı suyu akım modeli ile gelecekteki yeraltı su seviyesini araştırmışlardır. Mevcut giriş çıkış akım verilerinin ışığında, üç boyutlu zamana bağlı bir yeraltı suyu akım modeli oluşturularak bölgedeki yeraltı suyu seviyesini gelecek yıllar için tahmin etmişlerdir.

Mehdipour ve ark. (2013), İran Karaj ovasında üç gözlem kuyusunda yeraltı suyu seviyelerini tahmin etmek ve simule etmek için iki yapay zeka aracı olarak bir uyarlamalı sinirsel bulanık çıkarım sistemi (ANFIS) ve genetik programlama (GP) özelliğini araştırmışlardır. Bir akifer sistemine nüfuz eden gözlem kuyusundaki buharlaşma ve su seviyeleri, veri setlerindeki boşlukları doldurmak ve aylık yeraltı suyu seviyesi serilerini tahmin etmek için kullanılmıştır. Sonuçlar, GP'ye dayanan tahmin ve simülasyon yaklaşımının, yeraltı suyu seviyelerini belirlemede etkili bir araç olduğunu göstermiştir.

Üneş ve ark. (2015), ABD'deki Alabama nehri üzerindeki Millers Ferry Barajı için günlük rezervuar seviyelerini, YSA modelini kullanarak tahmin etmişlerdir. YSA modellerinin sonucu geleneksel otoregresif modeller (AR), otoregresif hareketli ortalama (ARMA), çoklu lineer regresyon (MLR) modelleri ile karşılaştırılmış ve YSA modellerinin geleneksel modellerden daha iyi performans gösterdiği tespit edilmiştir.

Babayiğit, (2015), meteorolojik veriler ve geçmiş günlere ait yeraltı su seviyeleri kullanarak yeraltı su seviyelerini tahmin etmek amacıyla matematiksel modellerin geliştirilmesine yeni bir GP yaklaşımı olan çok-genli genetik programlama (ÇGGP) uygulamıştır. ÇGGP ile model oluşturulmasında Karacaviran gözlem kuyusuna ait 2007-2010 zaman dilimini kapsayan dört yıllık günlük veriler ile Develi meteoroloji istasyonuna ait günlük meteorolojik veriler kullanılmıştır. Oluşturulan modellerin doğruluğu değerlendirilmiş ve çoklu doğrusal regresyon modelleri ile karşılaştırılmıştır. ÇGGP modelleri ile elde edilen sonuçların çoklu doğrusal regresyon modellerine göre dört farklı kritere göre daha iyi olduğu tespit edilmiştir.

Zhoo ve ark. (2016), Çin'in Shaxi kasabasında yer alan Three Gorges Rezervuar alanındaki Shuping heyelanının yeraltı suyu seviyesi izleme verileri, yağış ve rezervuar

seviyesi ve yeraltı suyu seviyesinin deęiřimi gibi etkili faktörleri kullanarak, sınıflandırma ve regresyon ağacı (CART) modelini oluşturmuş ve bu modeli yeraltı suyu seviyesinin tahmin edilmesinde kullanmışlardır. CART modelinin sadece daha iyi uyum ve genelleme kabiliyeti deęil, aynı zamanda heyelan yeraltı suyu dinamik özelliklerinin analizi ve önemli deęişkenlerin taranmasında güçlü avantajlar olduęu belirtilmiş ve heyelanlarda yeraltı suyu seviyesinin tahmini için etkili bir yöntem olduęunu tespit etmişlerdir.



### 3. MATERYAL ve YÖNTEM

Bu çalışmada, Kumlu bölgesinde bulunan DSİ rasat kuyusuna ait 2000 ile 2015 yılları arasındaki yeraltı su seviyesi aylık ölçüm değerleri ile Meteoroloji Müdürlüğünden alınan aylık toplam yağış ve ortalama sıcaklık değerleri kullanılarak klasik yöntem olarak MLR, AR ve yeni yöntem olarak adlandırılan YSA yöntemi ile bölgenin yeraltı su seviyesi tahmini yapılmıştır. Aşağıda bu yöntemler ile ilgili olarak temel bilgiler verilmektedir.

#### 3.1. Klasik Yöntemler

##### 3.1.1. Çoklu Lineer Regresyon Yöntemi (MLR)

Mühendislik problemlerinde iki veya daha çok rastgele değişkenin aynı gözlem sırasında aldıkları değerlerin birbirinden istatistik bakımdan bağımsız olmadığını, bu değişkenler arasında bir ilişkinin bulunduğu görülür. İki değişken arasında bir ilişki bulunması bunlardan birinin diğerinden etkilenmesi, ya da her iki değişkenin başka değişkenlerden birlikte etkilenmelerinden kaynaklanır. Örneğin bir akarsu havzasındaki akışla yağış arasındaki ilişki, akışın yağışın etkisiyle ortaya çıkmasından doğar. Komşu iki havzadaki akışlar arasındaki ilişki ise her ikisinin de o bölgedeki yağıştan etkilenmelerine bağlıdır. (Bayazit ve Oğuz, 2005)

Ancak, söz konusu ilişkiler deterministik (fonksiyonel) nitelikte değildir. Yani, değişkenlerden biri, belli bir değer aldığı anda, diğerinin her zaman aynı değeri alacağı söylenemez. Söz konusu ilişkide dikkate alınmayan diğer değişkenlerin etkisiyle bu değer çeşitli gözlemlerde az çok farklı olabilir. Örneğin, yanyana iki havzanın birinde akım belli bir değeri aldığı anda diğerindeki akım her zaman aynı değerde olmaz. Yine de değişkenler arasındaki fonksiyonel olmayan bağıntının varlığının ortaya çıkarılması ve biçiminin belirlenmesi pratikte büyük önem taşır. Zira, bu bağıntıyı kullanarak bir değişkenin alacağı değeri, diğer bir (ya da birden fazla) değişkenin bilinen değerlerine bağlı olarak tahmin etmek mümkün olur. Bu tahmin söz konusu değişkenin alacağı gerçek değeri kesin olarak vermemekle birlikte bu değere yakın en iyi tahmin olur. Tahmin edilen değer gerçeğe değerden olan farkının (hatanın) da belli bir olasılıkla hangi sınırlar içinde kalacağı söylenebilir.

Yukarıda sözü edilen tipten bir bağıntıyı gösteren matematik ifadeye Regresyon Denklemi denir. Regresyon analizinin amacı göz önüne alınan değişkenler arasında anlamlı bir ilişki bulunup bulunmadığını belirlemek, böyle bir ilişki varsa, bu ilişkiyi ifade eden regresyon denklemini elde etmek ve bu denklemi kullanarak yapılacak tahminlerin güven aralıklarını hesaplamaktır.

Regresyon analizinin inşaat mühendisliğinde kullanımına bir örnek olarak iki komşu havzada aynı yılda ölçülen akımlar arasındaki ilişkiyi gösterilebilir. Her iki akım da o yıl içinde bölgeye düşen yağıştan etkilendikleri için aralarında fonksiyonel olmayan bir ilişki vardır. Bu ilişkiyi gösteren regresyon denklemi elde edilebilirse bu denklemi kullanarak geçmişte havzalardan birinde ölçülmemiş olan eksik akım verilerini diğer havzada aynı yıllarda ölçülmüş olan akımlara bağlı olarak tahmin edilebilir. Tahmin edilen değerler gerçekte görülmüş olan değerlere eşit olmamakla birlikte yapılabilecek en iyi tahminler olurlar. Gerçek değer tahmin edilen değerden farkının belli bir olasılıkla hangi aralıkta kalacağı da hesaplanabilir.

Regresyon analizine başlarken aralarında bir ilişki aranacak olan iki (ya da daha fazla sayıda) değişkenin hangileri olduğuna karar vermek, sonra da bu değişkenler arasındaki ilişkiyi gösteren denklemin biçimi için bir kabul yapmak gerekir. Buna göre regresyon analizi şu şekilde sınıflandırılabilir:

Basit doğrusal regresyon analizi: En çok kullanılan bu en basit analizde iki değişken arasında doğrusal bir ilişki bulunduğu kabul edilir.

Çok değişkenli doğrusal regresyon analizi: İki'den daha fazla sayıda değişken arasında doğrusal bir ilişki bulunduğu kabul edilir.

Doğrusal olmayan (nonlinear) regresyon analizi: Burada iki ya da daha fazla sayıda değişken arasında doğrusal olmayan ve biçimi önceden seçilen bir denklemle ifade edilen bir ilişkinin varlığı kabul edilir (Bayazıt ve Oğuz, 2005).

Çok değişkenli regresyon ilişkisi Y bağımlı değişkeninin  $X_1, X_2, \dots, X_m$  gibi m bağımsız değişkenden etkilendiği kabul edilir ve aralarındaki ilişki için doğrusal bir denklem seçilirse y için regresyon denklemi şu şekilde yazılabilir:

$$y = a + b_1x_1 + b_2x_2 + \dots + b_mx_m \quad (3.1)$$

Bu denklemde y, bağımsız değişkenler  $X_1=x_1, X_2=x_2, \dots, X_m=x_m$  değerlerini aldığı anda y değişkeninin beklenen değerini göstermektedir.

a,  $b_1, b_2, \dots, b_m$  regresyon katsayıları basit regresyondakine benzer şekilde, gözlem noktalarının regresyon denkleminin gösterdiği düzlemde olan  $e_{yi}$  uzaklıklarının karelerinin toplamı olan,

$$\sum_{i=1}^N e_{yi}^2 = \sum_{i=1}^N \underbrace{(y_i - a - b_1 x_{1i} - b_2 x_{2i} - \dots - b_m x_{mi})^2}_y \quad (3.2)$$

ifadesini minimum yapacak şekilde hesaplanır (Bayazıt ve Oğuz, 2005).

### 3.1.2. Otoregresif Model (AR(p))

Bir rasgele değişkenin aldığı değerlerin zaman içinde belli aralıklarla ( $\Delta t$ ) izlenmesi halinde bir zaman serisi ( $X_1, X_2, \dots, X_i, \dots$ ) elde edilir. Ardışık anlardaki  $X_i$  ve  $X_{i+1}$  değerleri arasında istatistik anlamda bir bağımlılık bulunması halinde  $X_i$  bir stokastik süreç oluşturur.

Zaman serilerine İnşaat Mühendisliğinde özellikle hidrolojik uygulamalarda rastlanır. Bir akarsu kesitinde  $\Delta t$  aralıklarıyla ölçülen akımlar (ya da  $\Delta t$  aralığındaki toplam akım hacmi) bir zaman serisi oluşturur. Bu bölümde akım serilerinin istatistik analizinde kullanılan metotlar tanıtılacaktır (Bayazıt, 1996).

Yıllık akım serilerinin (trend ya da sıçrama bileşeni bulunmadığı takdirde) stasyonier oldukları kabul edilebilir. Buna karşılık zaman aralığının daha küçük alınması halinde (mevsim, ay, hafta, gün) yıl periyod olmak üzere bir periyodik bileşen bulunacağından akım serileri stasyonier olmayacaktır. Stasyonier olmayan serilerin incelenmesi güç olduğundan ileride görüleceği gibi bunların uygun bir dönüşümle stasyonier hale getirilmesine çalışılır.

Akarsu havzasının depolama özellikleri akım serilerindeki ardışık değerler arasında bağımlılık (iç bağımlılık) bulunmasına neden olur. Zaman aralığı kısaltıldıkça iç bağımlılık kuvvetlenir. Yıllık akımlar için en çok kullanılan modeller ARMA (autoregressive-moving average) sınıfı modellerdir. Bu sınıfta Markov modelleri olarak da bilinen lineer otoregresif modeller, hareketli ortalama modeller ve bu ikisinin karışımı şeklinde olan modeller bulunur. Model kurarken işlemleri basitleştirmek için veriler normalize edilerek kullanılır. Bu çalışmada sadece AR(p) modelleri kullanılacaktır.

### **Otoregresif Modeller (Markov Modelleri)**

p-inci mertebeye Markov modelinde (AR(p) modeli) i-inci yılın  $y_i$  akımı için şöyle bir ifade kabul edilir:

$$y_i = \sum_{j=1}^p \phi_j y_{i-j} + \epsilon_i = \phi_1 y_{i-1} + \phi_2 y_{i-2} + \dots + \phi_p y_{i-p} + \epsilon_i \quad (3.3)$$

Burada i-inci yılın akımının bundan önceki p yılın akımlarıyla doğrudan doğruya bağımlı olduğu görülmektedir. Modelde,  $\phi_i$  regresyon katsayıları,  $\epsilon_i$  bağımsız değişkendir. Bu çalışmada MATLAB yazılımı kullanılarak aylık yeraltı su seviyesi verilerine 1., 3. ve 5. mertebeden AR model uygulanmıştır.

### **3.2. Yapay Sinir Ağları (YSA) Modeli**

Yapay sinir ağları (YSA), insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri, herhangi bir yardım almadan otomatik olarak gerçekleştirilebilmek amacı ile geliştirilen bilgisayar sistemleridir (Öztemel, 2003).

Yapay sinir ağları; insan beyninden esinlenerek, öğrenme sürecinin matematiksel olarak modellenmesi uğraşı sonucu ortaya çıkmıştır. Bu nedenledir ki, bu konu üzerindeki çalışmalar ilk olarak beyni oluşturan biyolojik üniteler olan nöronların modellenmesi ve bilgisayar sistemlerinde uygulanması ile başlamış, daha sonraları bilgisayar sistemlerinin gelişimine de paralel olarak bir çok alanda kullanılır hale gelmiştir (Öztemel, 2003).


YSA'lar, değişken ağırlıkların bağlantıları ile bağlı birçok işlem ögesinden oluşan büyük paralel sistemlerdir. Burada ağırlıkları ayarlamak için kullanılan metodolojiye "Momentum geri yayılımı" denir ve Rumelhart ve ark. (1986) tarafından sunulan "Genelleştirilmiş Delta Kuralı" na dayanır.

YSA başlıca; Sınıflandırma, Modelleme ve Tahmin uygulamaları olmak üzere, pek çok alanda kullanılmaktadır. Başarılı uygulamalar incelendiğinde, YSA'ların çok boyutlu, gürültülü, karmaşık, kesin olmayan, eksik, kusurlu, hata olasılığı yüksek sensör verilerinin olması ve problemi çözmek için matematiksel modelin ve algoritmaların bulunmadığı, sadece örneklerin var olduğu durumlarda yaygın olarak kullanıldıkları görülmektedir (Öztemel, 2003).

#### **3.2.1. Yapay Sinir Ağlarının Biyolojik Kökeni**



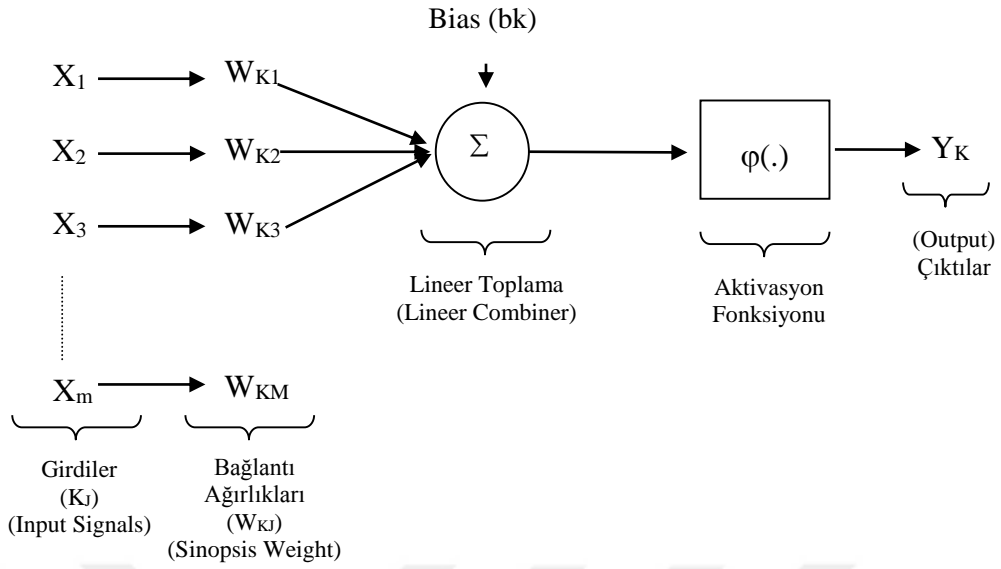
YSA biyolojik sinir ağlarının modellenmesi olduğu için, öncelikle biyolojik sinir sisteminin yapısına bakmak gerekir. Biyolojik sinir hücresinin şematik gösterimi Şekil 3.1’de verilmiştir. Biyolojik sinir sisteminin temel yapı taşı olan nöronların yapısı dört ana bölümden oluşmaktadır; Dendrit, Akson, Çekirdek ve Bağlantılar. Dendritlerin sinir hücresinin ucunda bulunan ve ağaç kökü görünümüne sahip bir yapıya sahiptir. Dendritlerin görevi bağlı olduğu diğer nöronlardan veya duyu organlarından gelen sinyalleri çekirdeğe iletmektir. Çekirdek Dendrit tarafından gelen sinyalleri bir araya toplayarak ve Aksona iletir. Toplanan bu sinyaller Akson tarafından işlenerek Nöronun diğer ucunda bulunan bağlantılara gönderilir. Bağlantılar ise yeni üretilen sinyalleri diğer Nöronlara iletir.



Şekil 3.1. Biyolojik sinir hücresinin yapısı

### 3.2.2. Yapay Sinir Hücresi

Nöronlar, yapay sinir ağlarının bilgi işleyen yapısal elemanlarıdır. Bir yapay sinir hücresi, girdiler (girişler), girdi ile çarpılan ağırlıklar, girdiye eklenen sabit değer (bias), toplayıcı (toplam fonksiyonu), aktivasyon fonksiyonu ve çıktı (beklenen değer) olmak üzere altı ana kısımdan oluşur.



Şekil 3.2. Yapay sinir ağı modeli

Girdiler; diğer hücrelerden ya da dış ortamlardan hücreye giren bilgilerdir. Bunlar ağıın öğrenmesi istenen örnekler tarafından belirlenir.

Ağırlıklar; girdi seti veya kendinden önceki bir tabakadaki başka bir işlem elemanının bu işlem elemanı üzerindeki etkisini ifade eden değerlerdir.

Toplam fonksiyonu; girdiler ve ağırlıkların tamamının bu işlem elemanına etkisini hesaplayan bir fonksiyondur. Bu fonksiyon bir hücreye gelen net girdiyi hesaplar.

Aktivasyon fonksiyonu; hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler.

Hücrenin çıktısı; aktivasyon fonksiyonundan çıkan değer hücrenin çıktı değeri olmaktadır. Bu değer ister yapay sinir ağıının çıktısı olarak dış dünyaya verilir isterse tekrardan ağıın içinde kullanılabilir. Her hücrenin birden fazla girdisi olmasına rağmen bir tek çıktısı olmaktadır. Bu çıktı istenilen sayıda hücreye bağlanabilir.


### 3.2.3. Aktivasyon Fonksiyonu Çeşitleri

#### *Doğrusal Aktivasyon Fonksiyonu*

Doğrusal problemler çözmek amacıyla aktivasyon fonksiyonu doğrusal bir fonksiyon olarak seçilebilir. Toplama fonksiyonundan çıkan sonuç, belli bir katsayı ile çarpılarak hücrenin çıktısı olarak hesaplanır. Doğrusal fonksiyon

$$y = x \quad (3.4)$$


şeklinde gösterilebilir. Doğrusal aktivasyon fonksiyonu grafik olarak Şekil 3.3'te gösterilmiştir.



Şekil 3.3. Doğrusal aktivasyon fonksiyonu

#### ***Adım Aktivasyon Fonksiyonu***

Gelen Net girdinin belirlenen bir eşik değerin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır. Adım aktivasyon fonksiyonu grafik olarak Şekil 3.4'te gösterilmiştir.




Şekil 3.4. Adım aktivasyon fonksiyonu

#### ***Sigmoid Aktivasyon Fonksiyonu***

Sigmoid aktivasyon fonksiyonu sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmayışı dolayısıyla yapay sinir ağı uygulamalarında en sık kullanılan fonksiyondur. Bu fonksiyon girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir. Sigmoid fonksiyonun matematik ifadesi

$$y = \frac{1}{1 + e^{-x}} \quad (3.5)$$

şeklindedir. Sigmoid aktivasyon fonksiyonu grafik olarak Şekil 3.5'te gösterilmiştir.



Şekil 3.5. Sigmoid aktivasyon fonksiyonu

#### ***Eşik Değer Fonksiyonu***

Gelen bilgilerin 0 dan küçük-eşit olduğunda 0 çıktısı, 1 den büyük-eşit olduğunda 1 çıktısı, 0 ile 1 arasında olduğunda ise yine kendisini veren çıktılar üretilebilir.

#### **3.2.4. Yapay Sinir Ağlarının Sınıflandırılması**

Yapay sinir ağları işleyiş olarak benzer olmalarına rağmen herhangi bir tasarım ve işleyiş standardı bulunmamaktadır. Nöron dizilimlerine, nöronların ağırlıklarının düzenleme için yapılan hesaplamaların türüne ve zamanına göre yapay sinir ağlarını üç ayrı dalda inceleyebiliriz.

#### ***Yapılarına Göre YSA***

YSA içerdiği nöronların birbirine bağlantı şekline göre ileri ve geri beslemeli olarak ikiye ayrılır (Öztemel, 2003).

*İleri Beslemeli Ağlar:* İleri beslemeli ağlarda nöronlar girişten çıkışa doğru düzenli katmanlar şeklindedir. Bir katmandan sadece kendinden sonraki katmanlara bağ bulunmaktadır. YSA'ya gelen bilgiler giriş katmanına daha sonra sırasıyla ara katmanlardan ve çıkış katmanından işlenerek geçer ve daha sonra dış dünyaya çıkar.

*Geri Beslemeli Yapay Sinir Ağları:* Geri beslemeli YSA'da ileri beslemeli olanların aksine bir hücrenin çıktısı sadece kendinden sonra gelen hücrenin katmanına girdi olarak verilmez. Kendinden önceki katmanda veya kendi katmanında bulunan herhangi bir hücreye de girdi olarak bağlanabilir.

Bu yapısı ile geri beslemeli yapay sinir ağıları doğrusal olmayan dinamik bir davranış göstermektedir. Geri besleme özelliğini kazandıran bağlantıların bağlantı şekline göre geri aynı yapay sinir ağıyla farklı davranışta ve yapıda geri beslemeli yapay sinir ağıları elde edilebilir.

### ***Öğrenme Algoritmalarına Göre Yapay Sinir Ağları***

Yapay sinir ağlarının verilen girdilere göre çıktı üretebilmesinin yolu ağı öğrenmesidir. Bu öğrenme işleminin de birden fazla yöntemi vardır. Yapay sinir ağları öğrenme algoritmalarına göre danışmanlı, danışmansız ve takviyeli öğrenme olarak üçe ayrılır (Öztemel, 2003).

*Danışmanlı Öğrenme:* Danışmanlı öğrenme sırasında ağa verilen giriş değerleri için çıktı değerleri de verilir. Ağ verilen girdiler için istenen çıktıları oluşturabilmek için kendi ağırlıklarını günceller. Ağı çıktılar ile beklenen çıktılar arasındaki hata hesaplanarak ağı yeni ağırlıkları bu hata payına göre düzenlenir.

Hata payı hesaplanırken ağı bütün çıktıları ile beklenen çıktıları arasındaki fark hesaplanır ve bu farka göre her hücreye düşen hata payı bulunur. Daha sonra her hücrenin kendine gelen ağırlıkları günceller.

*Danışmansız Öğrenme:* Danışmansız öğrenmede ağa öğrenme sırasında sadece örnek girdiler verilmektedir. Herhangi bir beklenen çıktı bilgisi verilmez. Girişte verilen bilgilere göre ağ her bir örneği kendi arasında sınıflandıracak şekilde kendi kurallarını oluşturur. Ağ bağlantı ağırlıklarını aynı özellikte olan dokuları ayırabilecek şekilde düzenleyerek öğrenme işlemini tamamlar.

*Destekleyici Öğrenme:* Bu öğrenme yaklaşımında ağı her iterasyonu sonucunda elde ettiği sonucun iyi veya kötü olup olmadığına dair bir bilgi verilir. Ağ bu bilgilere göre kendini yeniden düzenler. Bu sayede ağ herhangi bir girdi dizisiyle hem öğrenerek hem de sonuç çıkararak işlemeye devam eder.

### ***Öğrenme Zamanına Göre Yapay Sinir Ağları***

Yapay sinir ağları öğrenme zamanına göre de statik ve dinamik öğrenme olarak ikiye ayrılır (Öztemel, 2003).

*Statik Öğrenme:* Statik öğrenme kuralıyla çalışan YSA kullanmadan önce eğitilmektedir. Eğitim tamamlandıktan sonra ağı istenilen şekilde kullanılabilir. Ancak bu kullanım sırasında ağı üzerindeki ağırlıklarda herhangi bir değişiklik olmaz.


*Dinamik Öğrenme:* Dinamik öğrenme kuralı ise yapay sinir ağlarının çalıştığı süre boyunca öğrenmesini öngörerek tasarlanmıştır. Yapay sinir eğitim aşaması bittikten sonra da daha sonraki kullanımlarında çıkışların onaylanmasına göre ağırlıklarını değiştirerek çalışmaya devam eder.

### 3.2.5. YSA'nın Çalışma Ağına Yapısı

YSA'nın nöronlarının yapılanmasındaki yol özellikle ağı eğitmek için kullanılan öğrenme (Eğitme) algoritması ile ilgilidir. Bu yapılanma aşağıdaki gibi sınıflandırılır.

#### *Tek Tabakalı İleri Beslemeli Ağ*

Tek tabakalı yapay sinir ağlarında nöronlar tabaka şekline göre düzenlenir. Tabakalı ağın en basit formunda kaynak (girdi noktalarının) bir girdi tabakası ve nöronların (hesap noktaları), bir çıktı tabakası vardır. Bu tip tek tabakalı ağ YSA modellerinde pek alışılmış ve kullanılmış değildir. Diğer bir deyişle de bu tip ağ tamamen ileriye beslemeli bir tiptir.



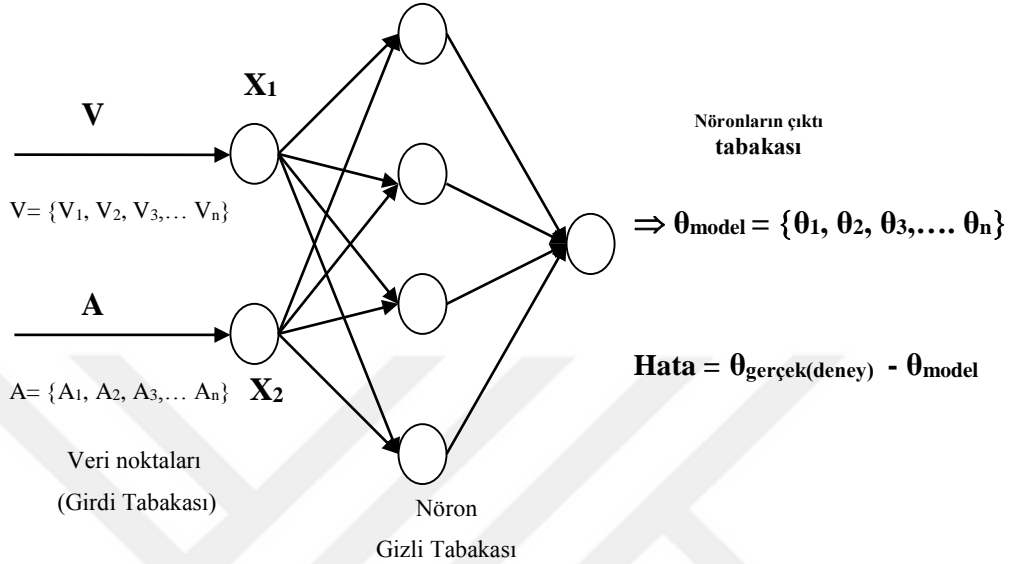
Şekil 3.6. Tek tabakalı ileri beslemeli ağ

#### *Çok Tabakalı İleri Beslemeli Ağ*

İleri beslemeli bir sinir ağının, bu ikinci sınıf formu, bir veya daha fazla gizli tabakaların oluşturulması ile kendi kendiliğinden ayırt edilebilir bir forma girmektedir. Bu gizli tabakaların hesaplanan noktaları şekilleri ile uyumlu olarak gizli nöronlar (hiddenlayers) veya gizli birimler olarak tanımlanır (hidden units).

Bu gizli tabakaların sinirlerinin fonksiyonu, hesaplarda faydalanılmak amacı ile, dış girdiler (veriler =inputlayer) ve hesap ağı çıktıları arasında yer alır.

Bir veya daha fazla gizli tabaka eklenerekte daha hassas dereceli istatistiksel sonuçlar elde etmek mümkündür.



Şekil 3.7. Tam bağlı ileri beslemeli bir gizli ve çıktı tabakalı hesap ağı

Çalışma ağının giriş verileri tabakasındaki girdi (input) verileri sırası ile girdi vektörlerinin elemanlarını oluşturur. Bunlar iki tabakadaki nöronlara uygulanan giriş verisi sinyallerinden oluşur.

Eğer YSA modeli birden fazla ara tabaka içeriyorsa ikinci tabakanın çıkış sinyalleri, üçüncü tabakanın girdi verileri olarak kullanılır ve çalışma ağının tümü için bu şekilde uygulanabilir. Su kaynakları mühendisliğinde yapılan uygulamalar için tek tabaka yeterli olacaktır.

Çalışma ağının çıktı tabakalarındaki (output) nöronların çıktı sinyallerinin kümesi, girdi (input) tabakasındaki verilerden elde edilen girdi vektörlerine YSA modelinin yanıtı olarak elde edilir.

Şekil 3.7’de ileri beslemeli sinir ağı 2-4-1 hesap ağı olarak tanımlanır. Sebebi de bu hesap ağı iki adet girdi noktası (source nodes), dört adet gizli nöron (hidden neurons) ve bir adet çıktı nöronuna (output neurons) sahip olmasıdır.

Bunun yanı sıra bu şekildeki nöron çalışma ağın tam bağlantılı (Fully connected) YSA modeli olarak isimlendirilir. Çünkü çalışma ağının her bir tabakasındaki her bir düğüm, önündeki komşu tabakalardaki her bir düğüm ile bağlanmıştır. Ancak eğer bu

iletme bağlantılarının (synaptic connections) bazıları eksik ise bu tip çalışma modeline kısmi bağlantılı YSA modeli denir.

### ***Hatayı Geriye Yayararak Eğitim***

Her bir tabakadaki nöronların sayısı ve bağlantı şekli belirli şartlar içerisinde değişebilir. Bir tabaka içerisindeki düğüm noktaları arasında (iletişim) bağlantı kurulmasına izin verilmez. Ancak her bir tabakadaki düğüm noktası değerleri, ardışık yani ondan sonraki tabakaya önceki tabaka çıktısı veya bulunduğu tabakanın girdisi olarak işlem yapabilir.

Düğüm noktalarına verilen veriler, hem başlangıçlardaki girdilerden (yani ilk girdi dosyalarından) hem de sonraki tabaka çıktılarından geri beslemelerinden ileri gelebilir. Bu geri besleme iki safha içerir: Girdi düğümlerindeki dışardan girilen verilerin bir ileri besleme safhası ile çıktı tabakasındaki çıktı bilgilerini hesaplayarak ileriye doğru yayılması. Çıktı gözlemlenen değerler ve hesaplananlar arasındaki farka (hataya) dayanarak bağlantı ağırlıklarını ( $w$ ; ağırlık-etkinlik katsayılarını) değiştirme-geri besleme fazında yapılır.

Eğitim işleminin başlangıcında, bağlantı eğitim algoritması, eğitim işlemini başarıyla tamamlayana kadar her bir iterasyonda düzeltilerek değiştirilir. Ağırlıkları rasgele değerler olarak alınarak başlanır.

Bu iterasyon işlemi (geriye doğru hataların yayılmasıyla yapılan) yakınsadığı zaman, bir ileri beslemeli hesap ağındaki YSA modeli ile elde edilen çıktı sonuçları değerlendirilerek o modelin sonucunda ağırlık katsayıları belirlenir.

Bir YSA modelinde  $N$  tane (girdi parametre verisi) girdi verisi vardır. Bu verilerin her biri girdi değerlerinin bir kümesine sahiptir. Buna  $X_i$  dersek;  $X_i = (i=1,2,3,\dots,k)$  kadar ve çıktı düğümlerinde  $J_n$ , ( $n= 1, 2, 3,\dots, m$ ) kadar çıktı değeri vardır. Bu girdi değerleri gizli tabakalardaki  $W_{ij}$  ( $j=1,2,3,\dots,h$ ) ile çarpılır ve çıkan değerler düzenlenerek gizli tabakaların girdi değerleri olarak kullanılır.

$$H_j = \sum_{i=1}^k W_{ij} \cdot X_i \quad (j = 1,2,3,\dots,h) \quad (3.6)$$

$H_j$  :  $j$ 'inci gizli tabakadaki girdi değerleridir.

$W_{ij}$  :  $i$ 'inci nöronun  $j$ 'inci nörona bağlantı, ağırlık katsayılarıdır.



Her bir gizli tabaka bir gizli tabaka, çıktısı üretmek için Sigmoid fonksiyonu (veya diğer fonksiyon) ile dönüştürülür veya işleme tabii tutulur.  $H_{Oj}$  olarak gösterilen çıktılar elde edilir.

$$H_{Oj} = f(H_J) = \frac{1}{1 + \exp[-(H_J + \theta_J)]} \quad (3.7)$$

$H_J$  : Düğüm noktalarındaki girdi değerleri

$f(H_J)$ : Çıktı düğüm noktası değeri


$\theta_J$  : Bir başlangıç veya Bias terimi olarak alınabilir.

Threshold (başlangıç) fonksiyonu, ( $\theta_J$ ) ağırlık katsayılarının eğitilmesine bir değer (genelde 1 alınır) olarak etkitilebilir.  $H_{Oj}$  çıktı değerleri ardışık tabakalarda girdi olarak da görev yapabilir. Birden fazla gizli tabaka alınması durumunda bu işlem çıktı tabakasına varıncaya kadar devam eder. Yani, kaç tane ara tabaka var ise her ara tabakanın çıktısı sonrakinin girdisi (inputu) olarak alınır ve bu işlem çıktı tabakasına kadar devam eder. Bu işlemin tümüne ileri doğru hareket akışı denir. Eğer  $n$  tane çıktı düğümü için girdi olarak  $I_{On}$  alınırsa aşağıdaki gibi ifade edebiliriz.

$$I_{On} = \sum_{j=1}^h W_{jn} \cdot H_{jn} \quad (n = 1, 2, 3, \dots, m) \quad (3.8)$$

Bütün girdi değerleri aktivasyon fonksiyonu ile yeniden tanımlanarak ( $O_n$ ) sinir ağının çıktı değerleri belirlenir. Çok tabakalı algılayıcının genel formu Şekil 3.8'de verilmiştir.

Yakınsak çözüm için ardışık olarak iterasyonlar boyunca ağırlıkların değiştirilmesi (hataların geriye yayılması) veya eğitme işlemlerinin geriye yayılması öğrenme algoritması ile başarılmaktadır. Çıktı tabakasındaki ( $O_n$ ) değerleri hedeflenen değerler ile (bulmayı amaçladığımız ölçüm veya model sonuçları) aynı olmayacaktır. Belirli bir miktar hata içerecektir.



Şekil 3.8. Çok tabakalı algılayıcı (perceptron)

$\theta_j$  Burada başlangıç fonksiyonu olarak alınır, bu terim yerine bias terimi genellikle kullanımlarda (1) olarak alınıp işlem yapılır.  $H_{Oj}$  çıktısı ise sigmoid fonksiyonu kullanılarak çıktı değerlerini ardışık gizli tabakalar boyunca input değerleri olarak almış ve output değerlerine kadar devam etmiştir.

Bu input değerleri YSA elde edilecek ( $O_n$ ) çıktı değerlerini vermesi için YSA modeli boyunca sürdürülüp yine eğitime işlemi ardışık ağırlık düzeltme işlemi ve geriye beslemeli eğitim algoritması ile başarılmaktadır.

YSA uygulanarak elde edilen çıktıya ( $O_n$ ) bulunması istenen ölçüm değerlerine ( $T_n$ ) denirse her bir girdi verisi için ( $e_p$ ) p'inci girdi verisinin çıktı sonucu oluşan hatası toplam karesel hataya göre yazılırsa ;

$$e_p = \sum_{l=1}^m (T_n - O_n)^2 \text{ dir.} \quad (3.9)$$

ve “MSE” ortalama karesel hataya göre hesaplanmak istendiğinde, tüm girdi verileri için toplam miktarı olarak;

$$E = \frac{1}{2N} \sum_{P=1}^N \sum_{n=1}^m (T_{p_n} - O_{p_n})^2 \quad (3.10)$$

burada,  $N$ ; bütün Girdi veriler,  $T_p$ : Gerçek veriler (bulunması istenen hedef değer),  $O_p$ ; YSA çıktı değerleridir.

Geri beslemeli algoritmanın amacı iteratif olarak ortalama karesel hataların minimize edilmesidir. Bu işlem çıktı tabakasındaki her bir bağ noktası için  $\delta_n$  hesaplanan değişim miktarını verir.

$$\delta_j = O_n(1 - O_n)(T_n - O_n) \quad (3.11)$$

burada  $\delta_j$  hatanın değişimidir ve bir önceki tabakadaki hesaplanan hataların ağırlıklı toplamları tarafından ara tabakalar için yenilenerek her bir iterasyon için belirlenir.

$$\delta_j = H_{O_j}(1 - H_{O_j}) \sum_{n=1}^m \delta_n \cdot W_{jn} \quad (3.12)$$

olarak yazılabilir. Burada,  $H_{O_j}$ ; girdi ve çıktı (input ve output) arasındaki ağırlık fonksiyonu ile verilen ilişkiden yola çıkarak,  $H_j$ , gizli tabaka girdisi ile  $O_j$ , çıktı değerine geçişi veren sigmoid fonksiyonu dönüşümüdür.

$$H_j = \sum_{i=1} W_{ij} \cdot X_i \quad (3.13)$$

ve

$$H_{O_j} = f(H_j) = \frac{1}{1 + \exp(H_j + O_j)} \quad (3.14)$$

Hata değerinin miktarı hesap ağının ağırlık değerlerini güncelleştirmede kullanılır.

$$\Delta W_{ij} = \eta \cdot \delta_j \cdot X_i \quad (3.15)$$

şeklinde yazılarak ağırlık değeri hataya göre yenilenir.

$$W_{ij}(r+1) = W_{ij}(r) + \Delta W_{ij} \quad (3.16)$$

Genellikle hızlı bir yakınsama sağlamak için eskalasyon (değerler arasındaki farksalınım) yol açmamak için geniş adım aralığı kullanılır. (r) ninci data girildikten sonra ağırlıklardaki değişim ise;

$$\Delta W_{ij}(r) = \eta \cdot \delta_j \cdot X_i + \alpha \Delta W_{ij}(r-1) \quad (3.17)$$

burada,  $\alpha$  ; Yakınsamayı hızlandırmak için kullanılan bir momentum oranı ifadesini,  $\eta$  ; hatanın değişiminde ve yayılımındaki adım aralığını belirleyen öğrenme oranı,  $r$ ; iterasyon sayısı,  $\delta_j$  ; hata miktarını göstermektedir.

### ***Öğrenme Oranı (Learning Rate $0 \leq \eta \leq 1$ )***

Öğrenme oranı  $\{0-1\}$  arasında belirlenir. Küçük bir öğrenme oranı “ $\eta$ ” için, bir iterasyondan diğerine çalışma ağındaki iletişim ağırlık çarpanının ( $W_{ij}$ ) değişimi daha küçük olacaktır.

Yani, daha küçük “ $\eta$ ” değeriyle daha yavaş bir öğrenmenin oluşmasına sebep olacaktır. Diğer taraftan çok yüksek bir “ $\eta$ ” değeri seçildiğinde YSA modeliyle oluşan çalışma ağı yakınsak bir sonuç vermeyebilir (unstable).

### ***Momentum Oranı katsayısı “ $\alpha$ ” (Momentum Rate $0 \leq \alpha \leq 1$ )***

Momentum katsayısı olaya dahil edilerek yakınsak (stable) ve doğru sonuca daha yakın bir değer elde edilebilir. Momentum oranı, grafiklerin veya verilerin dönüm noktalarındaki hata yüzeylerinde modelin öğrenme işlemini sonlandırmasını önleyebilir. Yani, momentum oranı Lokal minimumlarda YSA'nın iterasyona son vermesini önler.

Bir sonraki iterasyonda yayılacak hata miktarı aşağıdaki gibi verilmiştir.

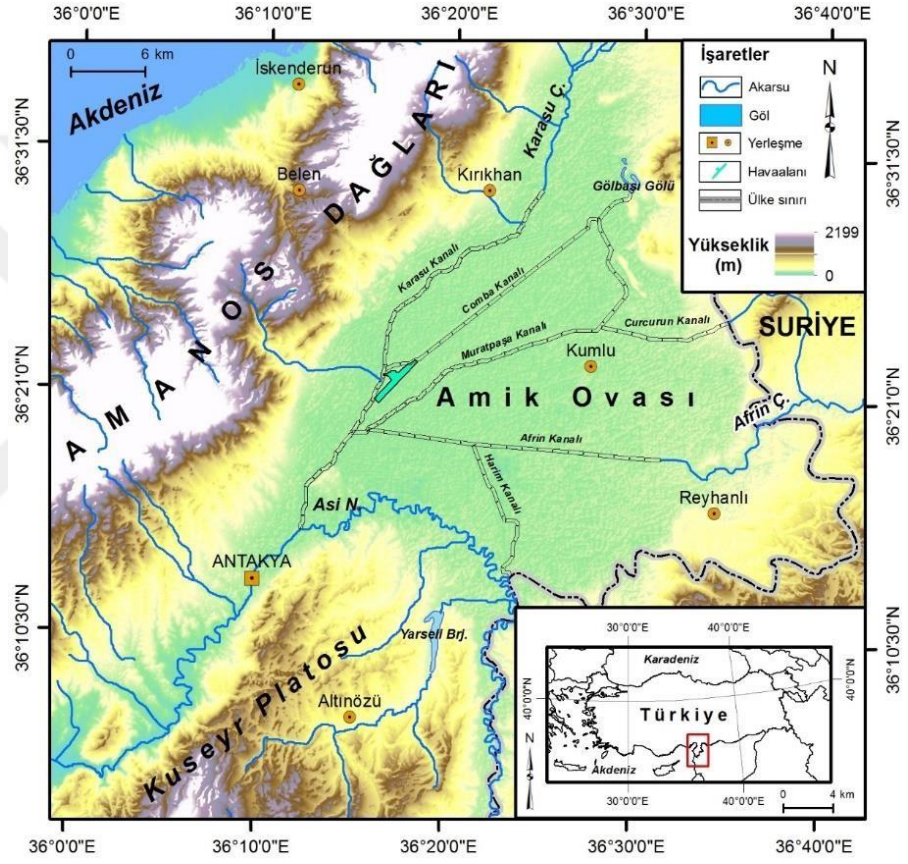
$$\Delta W_{ji}(r) = \eta \cdot \delta_i \cdot X_i + \alpha \Delta W_{ji}(r-1) \quad (3.18)$$

Bu çalışmada geriye beslemeli algoritma kullanılmıştır. Bu algoritma, doğru çözüme yaklaşımı hızlandırmak amacı ile en çok kullanılan algoritmalarından biridir (Kisi, 2004). Birçok YSA paradigmasının arasında, geri yayılım ağı çok daha popülerdir (Lippman, 1987). YSA modelinin uygulanması amacı ile istenilen girdi, çıktı ve eğitim sınırlarına göre MATLAB yazılım dilinde bir alt program yazılarak yeraltı su seviyesi tahmin değerleri belirlenmiştir.

## 4. ARAŞTIRMA BULGULARI ve TARTIŞMA

### 4.1. Uygulama Alanı ve Tanıtılması

Bu tez kapsamında çalışma alanı olarak Hatay ilinde bulunan Amik ovasının Kumlu bölgesi seçilmiştir. Asi havzasında yer alan Amik ovası, 36° 13' – 36° 30' Kuzey enlemleri ve 36° 12' – 36° 33' Doğu boylamları arasında olup yüzölçümü yaklaşık 65000 ha dır. Amik ovasının kuzeyinde Kırıkhan ilçesi, güneyinde Antakya ve Altınözü ilçeleri, doğusunda Reyhanlı ilçesi ile batısında Amanos dağları yer almaktadır (Şekil 4.1.).



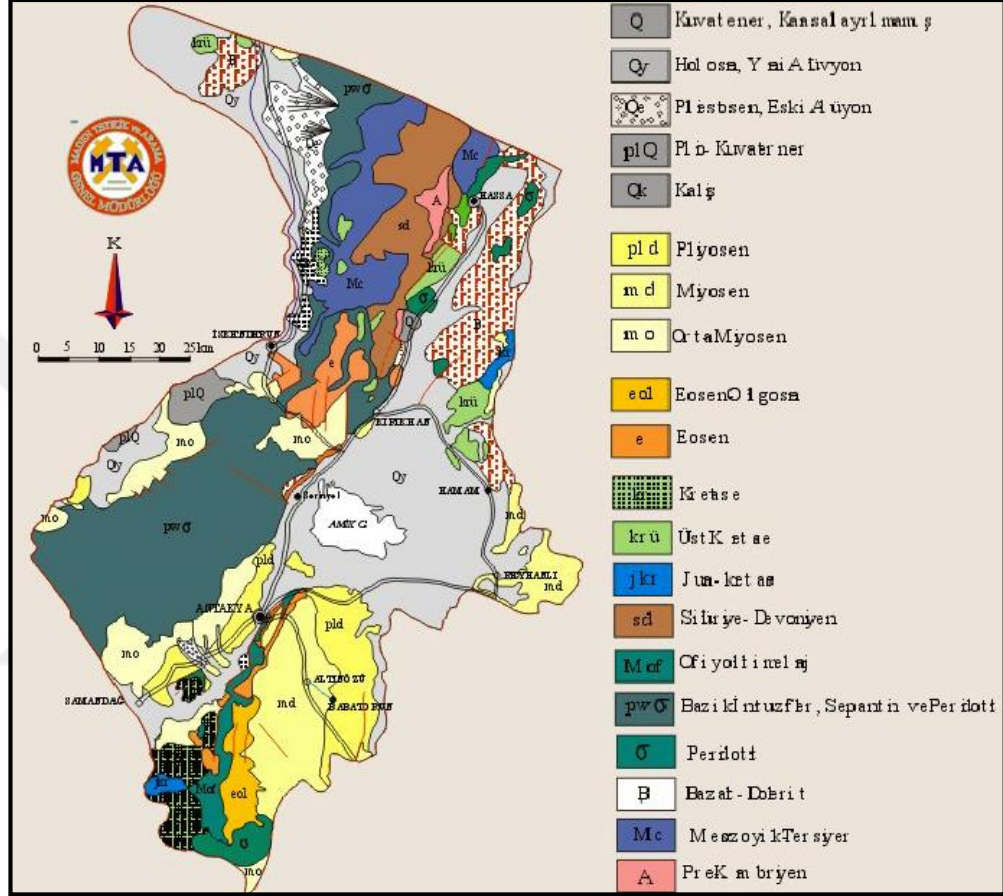
Şekil 4.1. Amik ovası haritası (Özşahin, 2013).

Amik ovası Akdeniz iklimi etkisinde olup yazları sıcak ve kurak, kışları ılık ve yağışlıdır. Uzun yıllar içinde gerçekleşen ölçüm verilerine göre, Hatay ilinde yıllık ortalama toplam yağış 1129 mm ve yıllık ortalama sıcaklıkta 18,2 °C dir (MGM, 2016).

Asi nehri başta olmak üzere Afrin, Muratpaşa ve Karasu çayları Amik ovasının önemli yerüstü su potansiyelini oluşturmaktadır. DSİ verilerine göre Hatay ilinin yeraltı suyu potansiyeli 298 hm<sup>3</sup>/yıl olarak tespit edilmiştir. Amik ovasının, Asi havzasında

149,50 hm<sup>3</sup>/yıl, Reyhanlı ilçesinde 8,32 hm<sup>3</sup>/yıl ve Kumlu ilçesinde 3,32 hm<sup>3</sup>/yıl yeraltı su potansiyeli tespit edilmiştir (ÇŞB, 2017).

Bölge jeolojik olarak genellikle alüvyon özellikte olup Amik ovasının kuzeydoğusu bazaltik özelliktedir (MTA, 2016). Hatay ilinin jeolojik özellikleri Şekil 4.2’de gösterilmektedir.






Şekil 4.2. Hatay ili jeoloji haritası (MTA, 2016).

Bu çalışmada, Amik ovasının kuzeydoğusunda bulunan Kumlu bölgesi incelenmiştir. Kumlu ilçesinde yer alan DSİ’ye ait 474 numaralı rasat kuyusunun 2000 – 2015 yılları arasındaki statik yeraltı su seviyesi aylık ölçüm verileri ile Antakya Meteoroloji istasyonunca ölçülen aylık toplam yağış ve aylık ortalama sıcaklık verileri kullanılmıştır. DSİ rasat kuyusu, 36.21981 enlemi ve 36.29114 boylamında yer almakta olup, derinliği 80 m’dir.

#### 4.2. Verilerin Değerlendirilmesi

Kumlu DSİ rasat kuyusunda ölçülen aylık yeraltı su seviyesi verileri ile Antakya Meteoroloji istasyonunca ölçülen aylık toplam yağış ve aylık ortalama sıcaklık verileri kullanılarak hangi modelin daha iyi sonuçlar verdiği araştırılarak karşılaştırmalar yapılmıştır. Bu çalışmada 2000 ile 2015 yılları arasında 16 yıllık ölçümü yapılan aylık yeraltı su seviyesi, aylık toplam yağış ve aylık ortalama sıcaklık değerlerine ait 192 veri kullanılarak modellemeler yapılmıştır. Aylık toplam yağış, aylık ortalama sıcaklık ve aylık yeraltı su seviyesi değerleri sırasıyla Şekil 4.3., Şekil 4.4., Şekil 4.5.'de grafiklerde gösterilmiştir. Tüm verilere ait değerler Ek 1'de yer almaktadır.





Şekil 4.5. Aylık yeraltı su seviyesi değişimi.

Bu uygulamada geçmişte yapılan benzer çalışmalarda olduğu gibi verilerin büyük kısmı eğitim için (yapılacak modellerin parametrelerinin elde edilmesi amacıyla) kullanılırken kalan kısım ise elde edilen modellerin test edilmesi için iki kısma ayrılmıştır. Model doğruluğunun kontrolü için ilk 150 veri modellemelerin eğitilmesi için, sonraki 42 veri de modellemenin test edilmesi için kullanılmıştır. Tüm veriler için istatistiksel parametre değişimleri Çizelge 4.1.'de, eğitim ve test verileri için ise Çizelge 4.2.'de gösterilmiştir. Bu çizelgelerde  $X_{max}$ ,  $X_{min}$ ,  $X_{ort}$ , sırasıyla verilerin maksimum, minimum, ortalama, değerlerini ifade etmektedir.  $S_x$ ,  $C_{sx}$ , değerleri de sırasıyla standart sapmayı ve çarpıklık katsayısını ifade etmektedir.

Çizelge 4.1. Tüm istatistiksel parametre değişimleri.

Veri Grubu	Değişkenler	T.Y.	O.S.	Y.A.S.S.
Tüm Veriler	$X_{max}$	0.64	29.80	12.50
	$X_{min}$	0.00	5.60	2.00
	$X_{ort}$	0.09	18.78	6.72
	$s_x$	0.10	7.13	2.35
	$c_{sx}$	1.71	-0.12	0.58

T.Y.: Aylık Toplam Yağış, O.S.: Aylık Ortalama Sıcaklık, Y.A.S.S.: Aylık Yeraltı Su Seviyesi,



Çizelge 4.2. Eğitim ve test istatistiksel parametre değişimleri.

Veri Grubu	Değişkenler	T.Y.	O.S.	Y.A.S.S.
Eğitim Verileri	Xmax	0.64	29.80	12.50
	Xmin	0.00	5.60	3.70
	Xort	0.09	18.56	7.20
	Sx	0.10	7.18	2.37
	Csx	1.79	-0.10	0.36
Test Verileri	Xmax	0.38	29.40	7.10
	Xmin	0.00	7.70	2.00
	Xort	0.09	19.59	5.01
	Sx	0.11	6.99	1.17
	Csx	1.51	-0.15	-0.28

T.Y.: Aylık Toplam Yağış, O.S.: Aylık Ortalama Sıcaklık, Y.A.S.S.: Aylık Yeraltı Su Seviyesi

#### 4.2.1. Model Sonuçları ve Değerlendirilmesi

Uygulamalarda 16 yıllık (192 aylık) veriler ile oluşturulan modellemelerin, Çoklu Lineer Regresyon (MLR), Otoregresif model AR(p) ve Yapay Sinir Ağları (YSA) sonuçları aşağıda yer almaktadır. Her bir model için ortalama karesel hata (MSE), ortalama mutlak hata (MAE) ve model tahminleri ve gözlemlenmiş değerler arasındaki korelasyon katsayıları (R) hesaplanmıştır. Sonuçlar model tahmini ve gözlem verilerinin performanslarını karşılaştırmak için kullanılmıştır. MSE ve MAE aşağıdaki gibi belirlenmiştir.

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_{i_{gözlenen}} - Y_{i_{tahmin}})^2 \quad (4.1)$$

ve


$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_{i_{gözlenen}} - Y_{i_{tahmin}}| \quad (4.2)$$

Burada N data set sayılarını ve  $Y_i$  yeraltı su seviyesi verilerini göstermektedir.


##### 4.2.1.1. MLR Model Sonucu

Çoklu lineer regresyon (MLR) için yapılan çalışmada 16 yıllık 192 adet verinin 150 verisi eğitim için 42 verisi de test için değerlendirilmiştir. Aylık Toplam Yağış (T.Y.),

Aylık Ortalama Sıcaklık (O.S.) ve Aylık Yeraltı Su Seviyesinin bir ötelenmiş zamanlı serisi (Y.A.S.S.+1) girdi olarak, Aylık Yeraltı Su Seviyesi (Y.A.S.S.) verisi de çıktı olarak kullanılarak regresyon modellenmiş ve sonuçlar aşağıdaki gibi belirlenmiştir. Eğitim verileri için dağılım ve saçılım grafikleri Şekil 4.6. ve Şekil 4.7. 'de gösterilmiştir.



Şekil 4.6. Yeraltı su seviyesi eğitim verileri için Ölçüm ve MLR dağılım grafiği



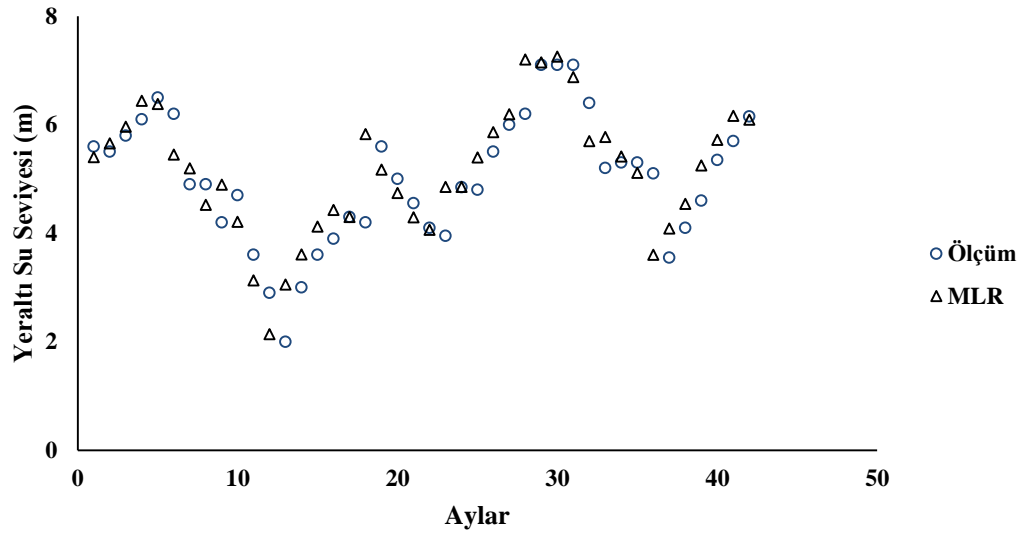
Şekil 4.7. Yeraltı su seviyesi eğitim verileri için Ölçüm ve MLR saçılım grafiği

Oluşturulan grafikte korelasyon katsayısı  $R=0,948$  elde edilmiştir. Korelasyon katsayısının iyi düzeyde olduğu ve gerçek değerlere yakın değerler verdiği görülmektedir.


Eğitim verilerine uygulanan regresyon sonucuna göre oluşan denklem;

$$Y = 0.5313 + 1,2795*X_1 - 0,0104*X_2 + 0,93659*X_3 \quad (4.1)$$

şeklinde olup bu denklem test verilerine uygulanmıştır. Denklem 4.1’de; 0,5313 sabit değeri;  $X_1$ , Yağış değişkenini;  $X_2$ , Sıcaklık değişkenini;  $X_3$ , YASS+1 değişkenini ifade etmektedir. Şekil 4.8. ve Şekil 4.9.’da test verileri için dağılım ve saçılım grafikleri gösterilmiştir.



Şekil 4.8. Yeraltı su seviyesi test verileri için Ölçüm ve MLR dağılım grafiği



Şekil 4.9. Yeraltı su seviyesi test verileri için Ölçüm ve MLR saçılım grafiği


Oluşturulan grafikte korelasyon katsayısı  $R=0,877$  elde edilmiştir. Test aşamasındaki MLR tahminlerinde de korelasyon katsayısının iyi düzeyde olduğu, yeraltı su seviyesi tahmininin gerçek değerlere yakın çıktığı görülmektedir.

#### 4.2.1.2. AR Modeli Sonucu


MLR modeline ilaveten yeraltı su seviyesi verilerine otoregresif model  $AR(p)$  uygulanarak çalışmanın kapsamı genişletilmiştir. Girdi katmanı ötelenmiş zamanlı aylık yeraltı su seviyesi verileri alınarak  $AR(1)$ ,  $AR(3)$  ve  $AR(5)$  modelleri oluşturulmuştur. Eğitim verilerine uygulanan zaman aralığı bir ötelenmiş  $AR(1)$  modeli sonucuna göre oluşan denklem;

$$y(I) = 0,9946*y_{t+1} \quad (4.2)$$

şeklinde olup bu denklem test verilerine uygulanmıştır. Aşağıda Şekil 4.10. ve Şekil 4.11.'de test verileri için dağılım ve saçılım grafikleri gösterilmiştir.



Şekil 4.10. Yeraltı su seviyesi test verileri için Ölçüm ve AR(1) dağılım grafiği

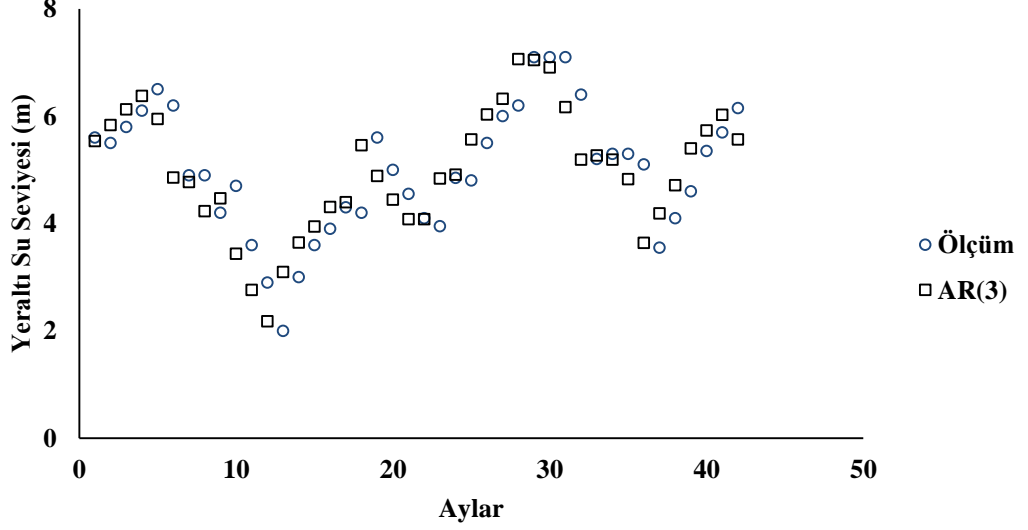


Şekil 4.11. Yeraltı su seviyesi test verileri için Ölçüm ve AR(1) saçılım grafiği


Eğitim verilerine uygulanan zaman aralığı üç ötelenmiş AR(3) modeli sonucuna göre oluşan denklem;

$$y(3) = 0,825*y_{t+1} + 0,1386*y_{t+2} + 0,0315*y_{t+3} \quad (4.3)$$

şeklinde olup bu denklem test verilerine uygulanmıştır. Test verileri için dağılım ve saçılım grafikleri Şekil 4.12. ve Şekil 4.13.'te gösterilmiştir.



Şekil 4.12. Yeraltı su seviyesi test verileri için Ölçüm ve AR(3) dağılım grafiği




Şekil 4.13. Yeraltı su seviyesi test verileri için Ölçüm ve AR(3) saçılım grafiği


Eđitim verilerine uygulanan zaman aralıđı beş ötelenmiş AR(5) modeli sonucuna göre oluşan denklem;

$$y(5) = 0,8193*y_{t+1} + 0,1319*y_{t+2} + 0,0139*y_{t+3} + 0,0482*y_{t+4} + 0,0785*y_{t+5} \quad (4.4)$$

şeklinde olup bu denklem test verilerine uygulanmıştır. Test verileri için dağılım ve saçılım grafikleri Şekil 4.14. ve Şekil 4.15. 'de gösterilmiştir.



Şekil 4.14. Yeraltı su seviyesi test verileri için Ölçüm ve AR(5) dağılım grafiđi




Şekil 4.15. Yeraltı su seviyesi test verileri için Ölçüm ve AR(5) saçılım grafiği

AR(1,3,5) modellemeleri sonucunda test verileri için dağılım ve saçılım grafikleri incelendiğinde AR mertebesi arttıkça R katsayısının düştüğü ancak, yeraltı su seviyesi tahminlerinin gerçek değerlere yakın olduğu görülmüştür.

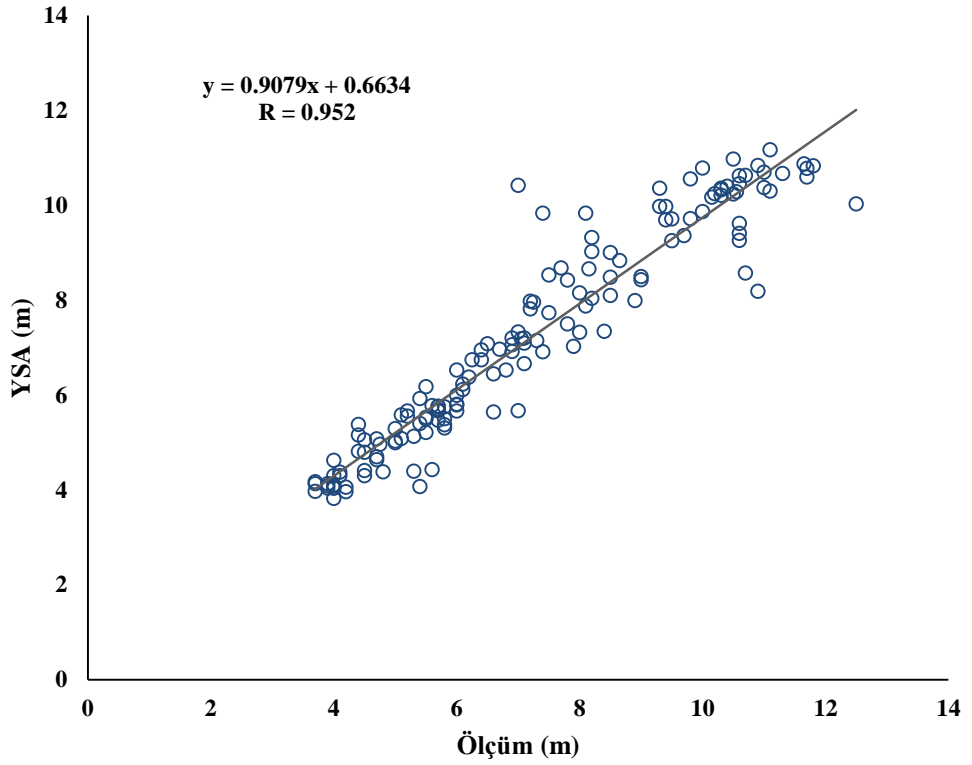
#### 4.2.1.3. YSA Model Sonucu

Yapay sinir ağları (YSA) modellemesi ile 16 yıllık 192 adet verinin 150 verisi eğitim için 42 verisi de test için kullanılarak analiz yapılmıştır. YSA uygulanırken girdi verileri olarak aylık toplam yağış (TY), aylık ortalama sıcaklık (OS) ve aylık yeraltı su seviyesi bir ötelenmiş zamanlı (YASS+1) verileri eklenmiş ve MATLAB programı ile 3 tabakalı geriye yayımlı YSA modeli ile yeraltı su seviyesi (YASS) tahmini yapılmıştır. Analiz sonucunda eğitim verileri için Şekil 4.16. ve Şekil 4.17.'de, test verileri için Şekil 4.18. ve Şekil 4.19'da dağılım ve saçılım grafikleri gösterilmiştir.






Şekil 4.16. Yeraltı su seviyesi eğitim verileri için Ölçüm ve YSA dağılım grafiği




Şekil 4.17. Yeraltı su seviyesi eğitim verileri için Ölçüm ve YSA saçılım grafiği

Oluşturulan grafikte  $R=0,952$  korelasyon katsayısının iyi düzeyde olduğu ve gerçek değerlere yakın değerler verdiği görülmektedir.



Şekil 4.18. Yeraltı su seviyesi test verileri için Ölçüm ve YSA dağılım grafiği.



Şekil 4.19. Yeraltı su seviyesi test verileri için Ölçüm ve YSA saçılım grafiği.

Aylık Toplam Yağış (TY), Aylık Ortalama Sıcaklık (OS) ötelenmiş zamanlı Yeraltı Su Seviyesi (YASS+1) verileri ile yapılan YSA modellemesi sonucunda test

verileri için dağılım ve saçılım grafikleri incelendiğinde R korelasyon katsayısının 0,888 olduğu ve yeraltı su seviyesi tahminlerinin gerçek değerlere yakın olduğu görülmüştür.

#### 4.2.2. Genel Değerlendirme

Kumlu bölgesine ait aylık toplam yağış, aylık ortalama sıcaklık, aylık yeraltı su seviyesi ve ileri zamanlı aylık yeraltı su seviyesi verileri kullanılarak MLR, AR(1,3,5) ve YSA modellerinin performans değerlendirmesi için korelasyon katsayısı (R), ortalama karesel hata (MSE), ortalama mutlak hata (MAE) hesaplanmıştır. Sonuçlar model tahmini ve gözlem verilerinin performanslarını karşılaştırılmıştır. 3 girdili verilerle oluşturulan modellemelerde test verileri için elde edilen MSE, MAE ve R parametrelerinin karşılaştırılması Çizelge 4.3.'te gösterilmiştir.

Çizelge 4.3. Kumlu bölgesine ait test verileri için elde edilen parametrelerinin karşılaştırılması

Yöntem	Giriş Verileri	MSE	MAE	R
MLR	TY, OS, YASS+1	0,341	0,457	0,877
YSA	TY, OS, YASS+1	0,290	0,419	0,888
AR(1)	YASS+1	0,433	0,528	0,837
AR(3)	YASS+3	0,466	0,564	0,820
AR(5)	YASS+5	0,465	0,560	0,817

MSE: Ortalama karesel hata, MAE: Ortalama mutlak hata, R: Korelasyon katsayısı

En iyi sonuç veren modelleme MSE, MAE' in en küçük, R'nin ise en büyük olduğu modellerdir. Çizelge 4.3 bu kriterlere göre incelendiğinde YSA modelinin MSE, MAE ve R değerleri için MLR modelinden daha iyi sonuç verdiği görülmüştür.

Yeraltı su seviyesi zaman serileri ile AR(1), AR(3) ve AR(5) otoregresif modellerin için yapılan testler neticesinde AR modeli ile yapılan tahminin iyi olduğu ancak YSA modeline göre tahmin düzeyinin düşük olduğu görülmüştür.

## 5. SONUÇ ve ÖNERİLER

Yeraltı suyu ile ülkemizde içme-kullanma, tarımsal sulama ve sanayi maksatlı önemli miktarda çekim yapılmaktadır. Nüfus artışı ile birlikte toplam su tüketimi sürekli artmaktadır. Su ihtiyacının karşılanabilmesi amacıyla yeraltı sularından yapılan aşırı çekimler neticesinde yeraltı su seviyesinde önemli düşmeler meydana gelmektedir. Etkin ve sürdürülebilir yeraltı suyu yönetiminin planlanabilmesi için yeraltı su seviyesinin tahmin edilmesi önem arz etmektedir.

Bu çalışmada, Amik ovasının kuzeydoğusunda yer alan Kumlu ilçesinde DSİ'ye ait rasat kuyusunun 2000 – 2015 yılları arasındaki statik yeraltı su seviyesi aylık ölçüm verileri ile Antakya Meteoroloji istasyonunca ölçülen aylık toplam yağış ve aylık ortalama sıcaklık verileri kullanılarak bölgenin yeraltı su seviyesi değerleri tahmin edilmeye çalışılmıştır.

Çoklu Lineer Regresyon (MLR), Otoregresif model (AR) ve Yapay Sinir Ağları (YSA) yöntemlerinin yeraltı su seviyesi tahminindeki performansları araştırılmıştır. Kumlu bölgesine ait aylık toplam yağış, aylık ortalama sıcaklık, aylık yeraltı su seviyesi ötelenmiş zamanlı YASS+1 verileri kullanılarak hangi modelin daha iyi sonuçlar verdiği araştırılarak karşılaştırmalar yapılmıştır.

Yapay Sinir Ağları modelinin MSE, MAE değerlerinin düşük ve R korelasyon katsayısının büyük olması bakımından Çoklu Lineer Regresyon modelinden daha iyi tahmin sonucu verdiği görülmüştür. Yeraltı su seviyesi zaman serileri ile AR(1), AR(3) ve AR(5) otoregresif modellerin için yapılan araştırma sonucuna göre de YSA modelinin tahmin düzeyinin daha yüksek olduğu görülmüştür.

Yapılan araştırma bulguları sonucunda yeraltı su seviyesinin Yapay Sinir Ağı modeli ile tahmin edilmesi, MLR ve AR(q) modelleri ile tahminine göre daha iyi sonuç verdiği tespit edilmiştir. Yeraltı su seviyesinin tahminine yönelik yapılacak çalışmalarda, diğer yöntemlere kıyasla daha doğru sonuçlar vermesi bakımından Yapay Sinir Ağları yönteminin alternatif bir model olarak kullanılabileceği sonucuna varılmıştır.

Yeraltı su seviyesinin tahmini konusunda YSA'nin geleneksel metotlardan daha avantajlı olmasının sebebi YSA yapısının problemin lineer olmayan dinamiklerini ve tüm data setlerini dahil etmesi olarak açıklanabilir.

Amik ovası Kumlu bölgesinin su yönetimi planlaması amacıyla yeraltı su seviyesi değişiminin düzenli ölçülmesi önem taşımaktadır. Bölgenin yeraltı su seviyesi tahmini

alıřmalarında yapay sinir ađları ynteminin kullanılması daha iyi sonular vermesi bakımından uygun olacaktır.

Bu alıřmada kullanılan yađıř miktarı, sıcaklık ve yeraltı su seviyesi verilerine ek olarak yzeyssel su kaynakları seviye deđerleri de kullanılarak ayrıca bir alıřma yapılabilir.



## KAYNAKLAR

- Akacan, S., 2005. Yapay sınır ağları ile yeraltı suyu zaman serisi modellemesi. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, 85 s, İstanbul.
- Aksoy, A.Ö., Güney, M.Ş. ve Scheytt, T., 2011. Torbalı bölgesinin zamanla değişen yeraltısuyu akım modeli. **İMO Teknik Dergi**, 22 (3): 5509-5522.
- Anonim, 2016. Diyardinnet. [www.diyadinnet.com/YararliBilgiler-884&Bilgi=madde-döngüsü-nedir](http://www.diyadinnet.com/YararliBilgiler-884&Bilgi=madde-döngüsü-nedir) Erişim tarihi: 18.06.2016
- Babayiğit, E., 2015. Meteorolojik veriler kullanılarak yeraltı su seviyesinin genetik programlama ile tahmini. Yüksek Lisans Tezi, Erciyes Üniversitesi, 78 s, Kayseri.
- Bayazıt, M., 1996. **İnşaat Mühendisliğinde Olasılık Yöntemleri**. İTÜ.
- Bayazıt, M., 2003. **Hidroloji**. Birsen Yayınevi. İstanbul.
- Bayazıt, M., ve Oğuz, B., 2005. **Mühendisler İçin İstatistik**. Birsen Yayınevi.
- Boogaard, H.F.P . Van den, Gautam, D.K. , Mynett, A.E . 1998. Auto-regressive neural networks for the modelling of time series, Hydroinformatics, Balkema, Rotterdam. The Netherlands, 741-768.
- Campolo, M., Andreussi, P., Soldati, A., 1999. River flood forecasting wiht a neural network model. **Water Resources Research**, 35(4), 1191-1197.
- Cigizoglu, H.K. and Kisi, O., 2005. Flow prediction by three back propagation techniques using k-fold partitioning of neural network training data. **Nordic Hydrology**. 36(1) 1–16.
- Coulibaly, P., Anctil, F., Aravena, R., Bobee, B., 2001. Artificial neural network modeling of water table depth fluctuations. **Water Resources Research**, 37 (4), 885–896.
- Coppola, E., Szidarovszky, F., Poulton, M., Charls, E., 2003. Artificial neural network approach for predicting transient water levels in multilayered groundwater system under variable state, pumping, and climate conditions. **J. Hydro. Eng.**, 8(6): 348-380.
- Coppola, E., Rana, A., Poulton, M., Szidarovszky, F., Uhl, V., 2005. A neural network model for predicting aquifer water level elevations. **Ground Water** 43 (2), 231–241.

- Coppola, E., Szidarovszky, F., Davis, D., Spayad, S., Poulton, M., Roman, E., 2007. Multi objective analysis of a public wellfield using artificial neural networks. **Ground Water** 45 (1), 53–61.
- ÇŞB, 2017. **Hatay ili 2016 yılı çevre durum raporu**. Hatay Çevre ve Şehircilik İl Müdürlüğü, 150 s, Hatay.
- DSİ, 2015. **DSİ 2015 faaliyet raporu**. Devlet Su İşleri Genel Müdürlüğü, 359 s, Ankara.
- Joorabchi, A., Zhang, H. and Blumenstein, M., 2009. Application of artificial neural networks to groundwater dynamics in coastal aquifers. **Journal of Coastal Research**, 56, 966 – 970, Australia.
- Feng, S., Kang, S., Huo, Z., Chen, S., Mao, X., 2008. Neural networks to simulate regional groundwater levels affected by human activities. **Ground Water** 46 (1), 80–90.
- Karaboran, O., 2013. Serbest akiferlerdeki yeraltı su seviyeleri ile meteorolojik veriler arasındaki ilişkinin yapay sinir ağları ile belirlenmesi. Yüksek Lisans Tezi, Erciyes Üniversitesi, 58 s, Kayseri.
- Kisi, O., 2004. River flow modeling using artificial neural networks. **ASCE Journal of Hydrologic Engineering**, 9 (1), 60–63.
- Lippman, R. 1987. An introduction to computing with neural nets, **IEEE ASSP Mag.**, 4, 4-22
- Maier, H.R., Dandy, G.C., 2000. Neural networks for the prediction and forecasting of water resources variables: a review of modeling issues and applications. **Environ. Modell.Softw.**15: 101–124.
- Mehdipour E.F., Haddad O.B., Marino M.A., 2013. Prediction and simulation of monthly groundwater levels by genetic programming. **Journal of Hydro-environment Research** 7 (2013) 253-260.
- MGM, 2016. Resmi İstatistikler. Meteoroloji Genel Müdürlüğü. <http://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?m=HATAY#sfB>
- MTA, 2016. Hatay İli Jeolojik Özellikleri. Maden Tetkik ve Arama Genel Müdürlüğü. <http://www.mta.gov.tr/v2.0/bolgeler/adana/bolgesel-jeoloji/jeoloji-hatay.pdf>
- Nayak, P.C., Satyaji Rao, Y.R., Sudheer, K.P., 2006. Groundwater level forecasting in a shallow aquifer using artificial neural network approach. **Water Resources Management** 20, 77–90.

- Özşahin, E., Kaymaz, Ç. G., 2013. Taşkın riskinin değerlendirmesine bir örnek: Amik ovası taşkınları. *Turkish Studies-International Periodical For The Languages, Literature and History of Turkish or Turkic* Volume 8/8 Summer 2013, 2021-2039, Ankara.
- Öztemel, E., 2003. **Yapay Sinir Ağları**. Papatya Yayıncılık Eğitim. İstanbul.
- Raman, H., Sunil Kumar, N., 1995, Multivariate modeling of water resources time series using artificial neural networks, **Hydrol. Sc.J.**, 40(2), 145-163.
- Ranjithan, S., Eheart, J. W., and Garrett, J. H. Jr. 1993. Neural network based screening for groundwater reclamation under uncertainty. **Water Resour. Res.**, 29(3), 563–57
- Rizzo, D.M., Dougherty, D.E., 1994. Characterization of aquifer properties using artificial neural networks: neural Kriging. **Water Resources Research** 30 (2), 483–497.
- Rogers, L. L., Dowla, F. U. 1994. Optimization of groundwater remediation using artificial neural networks with parallel solute transport modeling. **Water Resour. Res.**, 30(2), 457–481.
- Rumelhart, D. E., G. E. Hinton, and R. J. Williams, 1986. Learning internal representation by error propagation, in *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Vol. 1, pp. 318–362, Cambridge, MA: MIT Press.
- Szidarovszky, F., Coppola, E., Long, J., Hall, A., Poulton, M., 2007. A hybrid artificial neural network-numerical model for groundwater problems. **Ground Water** 45 (5), 590–600.
- Tayfur, G., Singh, V.P., 2006. ANN and fuzzy logic models for simulating event based rainfall-runoff. **Journal of Hydraulic Engineering**, 132 (12), 1321-1330.
- Tokar, A. S., Johnson, P. A., 1999. Rainfall-runoff modeling using artificial neural networks. **J. Hydrologic Engrg.**, ASCE, 4(3), 232– 239.
- UNEP, 2016. Global Water Resources. United Nations Environment Programme. [http://www.unep.org/training/programmes/Instructor%20Version/Part\\_2/Activities/Economics\\_of\\_Ecosystems/Water/Supplemental/Global\\_Water\\_Resources.pdf](http://www.unep.org/training/programmes/Instructor%20Version/Part_2/Activities/Economics_of_Ecosystems/Water/Supplemental/Global_Water_Resources.pdf)
- USDA, 2016. United States Department of Agriculture. [https://www.nrcs.usda.gov/Internet/FSE\\_MEDIA/nrcs143\\_025238.jpg](https://www.nrcs.usda.gov/Internet/FSE_MEDIA/nrcs143_025238.jpg)



- Üneş, F., Demirci, M. ve Kişi, Ö., 2015. Prediction of millers ferry dam reservoir level in usa using artificial neural network. **Periodica Polytechnica Civil Engineering**, 59(3), 309–318.
- Yocubal, İ., 2008. **Hidrojeoloji ders notları**. Kocaeli Üniversitesi, Jeoloji Mühendisliği Bölümü, 428 s, Kocaeli.
- Yoon, H., Hyun, Y., Lee, K.K., 2007. Forecasting solute breakthrough curves through the unsaturated zone using artificial neural networks. **Journal of Hydrology** 335, 68–77.
- Yurtçu Ş. ve İçağa Y., 2005. Akarçay havzası yeraltı suyu periyodik davranışının modellenmesi. **Teknolojik Araştırmalar Yapı Teknolojileri Elektronik Dergisi**, 1 (2): 21-28.
- Yücel, A., 2000. Yağış ve yeraltı suyu seviye rasatlarından faydalanarak Elazığ Uluova'nın yeraltı suyu bilançosunun hazırlanması. Yüksek Lisans Tezi, Fırat Üniversitesi, 61 s, Elazığ.
- Zhoo Y., Li Y., Zhang L., Wang Q., 2016. Groundwater level prediction of landslide based on classification and regression tree. **Geodesy and Geodynamics** 2016, vol 7 no 5, 348-355.

## ÖZGEÇMİŞ

Yazar, 1982 yılında Kahramanmaraş'ta doğdu. Hatay Payas Lisesinden 2000 yılında mezun oldu. Akdeniz Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği bölümünden 2005 yılında mezun oldu. 2005-2006 yıllarında özel sektörde çalıştı. Askerlik hizmetini tamamladıktan sonra 2007-2008 yıllarında serbest mühendislik yaptı. 2009-2010 yıllarında İstanbul Büyükşehir Belediyesi İmar Müdürlüğünde çalıştı. 2010-2016 yıllarında Devlet Su İşleri Genel Müdürlüğü Adana 6. Bölge Müdürlüğü Hatay 63. Şube Müdürlüğünde çalıştı. Halen Alanya Alaaddin Keykubat Üniversitesi Yapı İşleri ve Teknik Daire Başkanlığında çalışmaktadır.

**EKLER****EK 1. Hatay Kumlu Bölgesinde Kullanılan Tüm Verilerin Değerleri**

Yıl	Ay	Yeraltı Su Seviyesi (m)	Toplam Yağış (mm)	Ortalama Sıcaklık (°C)
2000	Ocak	6	310,7	6,7
	Şubat	6,1	185,7	9,2
	Mart	6	64,5	12,2
	Nisan	5,8	116,7	18,1
	Mayıs	5,3	2,8	21,2
	Haziran	5,3	0	26,1
	Temmuz	4,5	0	28,4
	Ağustos	4,4	4	28,2
	Eylül	5,4	25,8	25,7
	Ekim	6,1	41,5	20,3
	Kasım	6,2	29,5	14,6
Aralık	6,4	161,7	9,5	
2001	Ocak	6,5	88,4	10,1
	Şubat	6,9	208,4	10,5
	Mart	6,6	128,6	16,5
	Nisan	5,6	54,4	18,3
	Mayıs	4,4	638,5	21,2
	Haziran	4,7	0,5	25,7
	Temmuz	4,8	0	27,4
	Ağustos	4,5	1,9	28,3
	Eylül	5	17,8	26,1
	Ekim	5,5	53,3	21,5
	Kasım	6,25	113,1	13
Aralık	6,6	337	9,8	
2002	Ocak	6	204	7
	Şubat	5,5	92,9	12,4
	Mart	5,5	163,8	14,2
	Nisan	5,1	234,2	16,6
	Mayıs	5,4	11,6	21,1
	Haziran	4	9	25,5
	Temmuz	4	0	28,2
	Ağustos	3,7	15,2	27,8
	Eylül	4,2	27,5	25,6
	Ekim	4	30,4	21,8
	Kasım	4,7	69,2	15,6
Aralık	5,1	148,3	7,8	

Yıl	Ay	Yeraltı Su Seviyesi (m)	Toplam Yağış (mm)	Ortalama Sıcaklık (°C)
2003	Ocak	5	153,8	9,9
	Şubat	4,75	272,1	7,4
	Mart	4,7	233,9	11,3
	Nisan	3,9	45,4	16,8
	Mayıs	4	46,8	23,7
	Haziran	4	10,8	25,4
	Temmuz	4	18,9	27,8
	Ağustos	4,1	0	28,6
	Eylül	4,5	8,4	25,4
	Ekim	4,5	27,1	22,3
	Kasım	5,2	127	13,9
	Aralık	5,6	248,5	9,8
2004	Ocak	5,5	371,3	8,5
	Şubat	3,9	189,7	9,2
	Mart	3,7	30,4	14,6
	Nisan	4	70,6	17,3
	Mayıs	4,2	106,4	20,4
	Haziran	3,7	0	24,7
	Temmuz	3,9	0	27,8
	Ağustos	4,1	0	27,8
	Eylül	4,4	0	25,8
	Ekim	5	12,8	23,2
	Kasım	5,2	201,5	14,7
	Aralık	5,4	70,5	7,6
2005	Ocak	5,7	91,6	9,2
	Şubat	6	111,6	10
	Mart	5,7	123,1	14,1
	Nisan	5,7	82,7	17,7
	Mayıs	5,7	37,2	21,3
	Haziran	5,8	11,2	24,5
	Temmuz	5,7	6,9	27,2
	Ağustos	5,7	0	28
	Eylül	6	206,6	25,2
	Ekim	6,4	71	19,2
	Kasım	6,9	114,7	13
	Aralık	7	112,5	11,1

Yıl	Ay	Yeraltı Su Seviyesi (m)	Toplam Yağış (mm)	Ortalama Sıcaklık (°C)
2006	Ocak	7,1	180,5	7,5
	Şubat	7,2	134	10,4
	Mart	7,5	182,7	14,2
	Nisan	7,4	39	18
	Mayıs	6,9	14,9	21,9
	Haziran	7,1	0	25,3
	Temmuz	6,8	0	27,3
	Ağustos	6,7	0	28,2
	Eylül	7,1	62,7	25,9
	Ekim	7,2	98,2	20,9
	Kasım	7,8	123,4	12,5
	Aralık	8,1	6,5	8,4
2007	Ocak	9,8	109,4	7,6
	Şubat	9,5	198,8	10,6
	Mart	9,4	130,4	13,9
	Nisan	9,5	124,2	15,9
	Mayıs	9	32,7	22,6
	Haziran	8,4	4,4	25,6
	Temmuz	7,4	0	28,2
	Ağustos	10	0	28,4
	Eylül	11,65	31,9	26,4
	Ekim	11,8	12,1	22,7
	Kasım	11,7	158,8	15
	Aralık	10,9	211	8,6
2008	Ocak	11,3	126,1	5,6
	Şubat	11	127,9	9,5
	Mart	11,1	109,5	16,5
	Nisan	12,5	27,3	19,1
	Mayıs	10,15	87,1	20,9
	Haziran	10,3	21,3	25,9
	Temmuz	10,5	0	28,1
	Ağustos	10,6	1,6	28,6
	Eylül	9,3	276,9	25,5
	Ekim	10,4	75,5	20,7
	Kasım	10,7	133,7	15,4
	Aralık	11	99,5	8,3

Yıl	Ay	Yeraltı Su Seviyesi (m)	Toplam Yağış (mm)	Ortalama Sıcaklık (°C)
2009	Ocak	10,5	165,8	7,5
	Şubat	11,7	272	10,5
	Mart	11,1	182,8	12,8
	Nisan	10,3	293,5	17,1
	Mayıs	10,3	51,4	21,1
	Haziran	10,6	0	26,3
	Temmuz	9,7	5,3	27,9
	Ağustos	9,4	0	28,4
	Eylül	10,2	17,3	24,8
	Ekim	10,55	15,4	22,8
	Kasım	10,6	170	14,4
	Aralık	10,6	394	12,2
2010	Ocak	10,6	222,3	11,3
	Şubat	9	124,9	11,9
	Mart	8,1	62,9	15,4
	Nisan	7,7	57,2	18,1
	Mayıs	8,5	39,2	21,8
	Haziran	8	62,9	25,2
	Temmuz	7,3	0	27,3
	Ağustos	7,25	0	29,8
	Eylül	8	5,8	27,3
	Ekim	8,15	75	22,2
	Kasım	8,5	0	16,5
	Aralık	8,9	257,2	11,3
2011	Ocak	7,5	106,9	9,2
	Şubat	8,2	154,8	10,4
	Mart	8,65	143,5	13,7
	Nisan	8,5	130,4	17,1
	Mayıs	8,2	65,1	20,9
	Haziran	7,9	86,3	24,7
	Temmuz	7	0	27,6
	Ağustos	10,9	0	28,5
	Eylül	8,2	34,7	26,6
	Ekim	9,3	82,5	19,7
	Kasım	10	58,6	11,1
	Aralık	9,8	190,9	8,2

Yıl	Ay	Yeraltı Su Seviyesi (m)	Toplam Yağış (mm)	Ortalama Sıcaklık (°C)
2012	Ocak	10,7	418,1	7,4
	Şubat	7,8	243,6	8,5
	Mart	7,05	105,2	12,4
	Nisan	7	16,5	18,8
	Mayıs	5,8	97,6	21,6
	Haziran	5,8	1,6	26,3
	Temmuz	5,6	14,1	28,9
	Ağustos	5,5	0	29,4
	Eylül	5,8	0	27,3
	Ekim	6,1	42,5	22,2
	Kasım	6,5	164,1	15,9
	Aralık	6,2	341,2	10,2
2013	Ocak	4,9	131,3	8,9
	Şubat	4,9	146,7	12,2
	Mart	4,2	87,5	14,4
	Nisan	4,7	383,4	17,8
	Mayıs	3,6	95,1	23,1
	Haziran	2,9	0	25,4
	Temmuz	2	0	27,6
	Ağustos	3	0	28,4
	Eylül	3,6	158,9	25,6
	Ekim	3,9	47,8	18,5
	Kasım	4,3	7,4	16,8
	Aralık	4,2	104,6	7,8
2014	Ocak	5,6	55,5	10,8
	Şubat	5	55,2	12
	Mart	4,55	67,8	15,7
	Nisan	4,1	20,7	18,9
	Mayıs	3,95	6,4	21,9
	Haziran	4,85	70,6	25,2
	Temmuz	4,8	0	27,4
	Ağustos	5,5	4,6	28
	Eylül	6	98,5	26
	Ekim	6,2	184,4	20,8
	Kasım	7,1	84,1	13,5
	Aralık	7,1	155,2	12,2

Yıl	Ay	Yeraltı Su Seviyesi (m)	Toplam Yağış (mm)	Ortalama Sıcaklık (°C)
2015	Ocak	7,1	336,9	7,7
	Şubat	6,4	314,9	10,3
	Mart	5,2	335,9	14,4
	Nisan	5,3	79,1	17,3
	Mayıs	5,3	24,6	21,9
	Haziran	5,1	2	24,5
	Temmuz	3,55	0,9	27,5
	Ağustos	4,1	5	29,2
	Eylül	4,6	0,2	28,3
	Ekim	5,35	68,6	22,6
	Kasım	5,7	27,7	15,9
	Aralık	6,15	39,6	10,4